

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/319305437>

"Processeurs Paralleles Optoelectroniques Stochastiques pour le traitement d'images en temps reel" (Optoelectronic Stochastic Parallel Processors for real time image processing and...

Thesis · September 2000

CITATIONS

0

READS

35

1 author:



[Alvaro Cassinelli](#)

City University of Hong Kong

68 PUBLICATIONS 507 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



Furniture learns to move itself with vibration [View project](#)



Tangible, Spatialized Databases [View project](#)

ORSAY
n° d'ordre :

Université de PARIS-SUD
CENTRE D'ORSAY

THESE

présentée
pour obtenir le titre de
Docteur en Sciences
de l'Université PARIS XI ORSAY
par
Alvaro CASSINELLI

Spécialité : **Lasers et Matière**

Processeurs Parallèles Optoélectroniques Stochastiques pour le traitement d'images en temps réel

Soutenue le 21 septembre 2000 devant la Commission d'examen :

Pierre CHAVEL	Directeur de thèse
Marc P. Y. DESMULLIEZ	Rapporteur externe
Francis DEVOS	Président du jury
Denis GINGRAS	Invité
Alain MARUANI	
Philippe REFREGIER	Rapporteur externe

Remerciements

Je tiens à exprimer tous mes remerciements

à Francis DEVOS pour m'avoir fait l'honneur de présider le jury de thèse ;

à Marc DESMULLIEZ et Philippe REFREGIER pour leur attention toute particulière sur mon travail en qualité de rapporteurs, malgré le court délai qui leur aura été imposé ;

à Alain MARUANI et Denis GINGRAS pour avoir accepté de participer au jury ;

à Pierre CHAVEL qui m'a fait l'honneur de m'accueillir dans son équipe, d'encadrer mon travail et enfin de corriger mon manuscrit de thèse. Il m'a laissé une marge de liberté considérable sans pour autant jamais manquer à l'écoute ni aux conseils ; je garde de sa tutelle un exemple de rigueur scientifique et de sa personne un modèle de probité ;

à Philippe LALANNE pour son dynamisme contagieux et des conseils qui souvent dépassèrent le cadre scientifique ;

à Jean Claude RODIER et André VILLING, sans lesquels la partie électronique du démonstrateur n'aurait jamais fonctionné (...elle n'aurait même pas existé !) ;

aux stagiaires Nicolas NICEPHORE et Attila SÜTO qui ont fourni un travail important de simulation informatique, ainsi qu'au stagiaire Lionel HEUSEY et au scientifique du contingent Christophe VITRE pour l'aide précieuse apporté à la réalisation des hologrammes.

à tous les doctorants (et ex-doctorants) du groupe Physique des Images avec qui j'ai eu le plaisir de partager tant de bons moments et qui ont eu la patience de supporter, entre deux réglages micrométriques, des nombreuses questions techniques mais aussi métaphysiques. Ainsi, un grand merci à Thomas GRUDZIEN et son faisceau gaussien pas trop crédible, à Nelson DE OLIVEIRA qui m'aura appris beaucoup sur une certaine façon de voir le monde (et les lapins), à Pierre PICHON et sa bonne humeur trempé à l'eau de mer, à Laure LEE, un poisson tropical et souriant qui n'a pas peur du travail, et à Pascale PARREIN, qui possède l'art de la science mais aussi la science de l'art et qui les fait partager avec générosité.

...et bien sûr à tous les membres de l'équipe Physique des Images pour leur disponibilité et l'ambiance chaleureuse qu'ils savent entretenir. Un grand merci à Nathalie BAUDRY pour l'aide administrative et à Jacqueline BESSAGUET pour l'aide apporté à la reproduction de ce mémoire.

Enfin, la place me manquera bien sûr pour remercier tous les proches qui m'ont accompagné et appuyé en dehors du laboratoire et sans lesquels ce travail n'aurait sûrement pas abouti. Mais comment passer sous silence l'amour et l'aide sans faille que

mes parents et mes frères Horacio et Eduardo m'ont toujours prodigué et qui m'ont permis de surmonter nombre d'écueils matériels et psychologiques? Ce ne sont pas les seules personnes envers lesquelles je suis en dette ; ainsi je serai toujours reconnaissant à Philippe PINEL (inestimable compagnon de route et élément résonant essentiel – mais toujours critique - de mes élucubrations intellectuelles), à Delphine CHEVRY, à Thomas PEDROLETTI, à Giulia DEVECCHI, à Gonzalo FRASCA, à Min KYUNG CHO, à Christophe VERJUS, à André PIRODEAU, à Jean-Baptiste FORTIN&Hélène LAGOUTE, à Cedric BINAU, à Thierry TOMASI, à Grégory LECLERC, à Beatriz MONTERO, à Emmanuel FORT, à Nicolas LEUILLOT, à Barbara FAYARD, à Monica BRESSAGLIA,... et à tant d'autres encore qui ont chacun à leur manière (et parfois même à leur insu) contribué à l'heureuse issue de ce travail.

Sommaire

Remerciements _____	2
Sommaire _____	4
Table des matières _____	5
Introduction _____	10
Chapitre I : Champs de Markov en analyse d'images _____	20
Chapitre II : Recuit Simulé Parallèle _____	43
Chapitre III : Prototype VLSI-CMOS _____	79
Chapitre IV : La détection du mouvement _____	104
Chapitre V : Un démonstrateur pour la détection du mouvement ____	150
Chapitre VI : Résultats expérimentaux _____	180
Chapitre VII : Vers une nouvelle puce à entrées et sorties optiques ____	204
Conclusion générale _____	259
ANNEXES _____	262
Annexe A : Modulateur Spatial de Lumière _____	263
Annexe B : Hologrammes synthétiques pour la convolution optique ____	270
Annexe C : Description des séquences de mouvement _____	284
Annexe D : Interface informatique _____	298
Références bibliographiques _____	306

Table des matières

Introduction	10
Chapitre I : Champs de Markov en analyse d'images	20
1. Introduction	20
2. Régularisation Bayésienne	23
2.1 Introduction et notations	23
2.2 Règle de Bayes	24
2.3 Lien statistique entre observation et étiquettes.	25
2.4 Probabilité <i>a priori</i> : modèle Markovien spatial.	27
3. Champs de Markov.	28
3.1 Définitions.	28
3.2 Théorème d'équivalence	29
3.3 Le problème de l'estimation des paramètres.	31
4. Estimateur MAP et minimisation de l'énergie	32
4.1 Construction de la fonction de coût.	32
4.2 Remarque : estimateurs MPM et MF.	33
5. Quelques exemples	34
5.1 Débruitage d'images binaires et modèle d'Ising.	34
5.2 Codage en demi-teintes.	40
6. Conclusion	42
Chapitre II : Recuit Simulé Parallèle	43
1. Introduction	43
1.1 Quelques exemples de problèmes d'optimisation.	44
1.2 Les algorithmes d'optimisation : généralités.	47
2. Algorithmes stochastiques	48
2.1 Introduction	48
2.2 Les procédures d'échantillonnage dynamiques	49
2.3 La procédure de refroidissement ou <i>Recuit Simulé</i>	68
3. Algorithmes déterministes	72
3.1 Introduction	73
3.2 Stochastique vs déterministe	74
4. Cahier de charges pour un processeur dédié au recuit simulé parallèle.	77
5. Conclusion	77

Chapitre III : Prototype VLSI-CMOS pour le Processeur Parallèle	
Optoélectronique Stochastique	79
1. Introduction	79
2. Rétine artificielle ou machine de Boltzmann ?	80
2.1 Une rétine artificielle pour la restauration d'images...	80
2.2 ...une machine de Boltzmann.	83
3. Architectures optoélectroniques pour la machine de Boltzmann.	84
4. Une machine de Boltzmann simplifiée pour le traitement d'images : le PPOS.	86
5. Présentation du processeur SPIE600	87
5.1 Architecture électronique globale	88
5.2 Le processeur élémentaire.	88
5.3 Le générateur de nombres aléatoires optique (RNG)	89
5.4 Conclusion.	95
6. Le recuit simulé sur SPIE600.	96
6.1 Modèle du Verre de Spin	96
6.2 Débruitage d'images binaires à cadence vidéo.	98
7. Conclusion	103
7.1 Nombre de recuits sérieux à la seconde sur SPIE600.	103
7.2 Performances pour le débruitage d'images.	103
Chapitre IV : La détection du mouvement	104
1. Introduction	104
2. L'analyse du mouvement	105
2.1 Introduction	105
2.2 Hiérarchie fonctionnelle dans les systèmes de vision.	106
3. La détection du mouvement	107
3.1 Introduction.	107
3.2 Description du problème.	108
4. Obtention du masque des objets mobiles (MB)	109
4.1 Utilisation d'une image de référence.	109
4.2 Utilisation de la carte des changements temporels.	109
4.3 Techniques diverses pour l'obtention directe du MB.	113
4.4 Conclusion	114
5. Régularisation markovienne de la CCT	114
5.1 Introduction	114
5.2 Interprétation des variables.	115
5.3 Description des algorithmes de Lalande et Dumontier.	118
5.4 Un modèle complet mais gourmand en calcul : le modèle de Lalande.	119
5.5 Le modèle simplifié de Dumontier.	125
5.6 Estimation des paramètres.	130
5.7 Conclusion	131
6. Modèle proposé pour la détection du mouvement	133

6.1 Introduction	133
6.2 Description du nouveau modèle	133
7. Simulation et performances	143
7.1 Qualité du masque des objets mobiles MB.	144
7.2 Charge de calcul.	148
8. Conclusion	149
Chapitre V : Un démonstrateur utilisant le PPOS pour la détection du mouvement.	150
1. Introduction	150
1.1 Principe de fonctionnement.	150
2. Architecture Optique	153
2.1 Introduction.	153
2.2 Grandissement du système d'imagerie (bras A et B).	154
2.3 Eclairage moyen sur les photodétecteurs.	160
2.4 Système télécentrique et afocal.	163
3. Autres éléments optiques	165
3.1 Modulateur Spatial de Lumière.	165
3.2 Eléments diffractifs (DOE) pour la convolution optique.	165
4. Sources Optiques	166
4.1 Destruction de la cohérence spatiale de la source optique.	166
5. Bilan optique et choix des sources laser.	169
5.1 Définition des quantités utiles.	170
5.2 Equation du bilan optique.	171
5.3 Choix des diodes laser.	173
5.4 Uniformité d'éclairage système Diode/Fibre/SLM.	174
6. Interface et cartes électroniques	175
6.1 Interface électronique.	175
6.2 Interface informatique pour le démonstrateur	175
7. Conclusion	176
Chapitre VI : Résultats expérimentaux	180
1. Mise en route de l'expérience	180
1.1 Réglages optomécaniques.	180
1.2 Boucle de rétroaction.	181
1.3 Ajustement des paramètres	184
1.4 Conclusion	192
2. Démonstration	194
2.1 Débruitage d'images binaires avec voisinage optique.	194
2.2 Détection du mouvement.	197
2.3 Rendu en demi-teintes ou B-codage d'images.	199
3. Conclusion	199
3.1 Qualité du traitement.	199

3.2 Performances du prototype.	200
3.3 Sur les interconnexions optiques en espace libre	203
Chapitre VII : Vers une nouvelle puce à entrées et sorties optiques.	204
1. Motivations.	204
2. Les circuits intégrés optoélectroniques (OEVLSI).	205
2.1 Introduction	205
2.2 Bus optique vs bus électronique	206
2.3 Les Matrices de Pixels Intelligents (<i>Smart Pixels Arrays</i>)	208
2.4 Caractérisation des circuits et systèmes optoélectroniques.	213
2.5 Conclusion	224
3. PPOS à entrées et sorties optiques : cahier de charges	226
3.1 Fonctionnalités de la puce.	226
3.2 Performances attendues et choix de la technologie	229
3.3 Conclusion	234
4. Le PPOS en technologie hybride CMOS-SEED.	236
4.1 Les dispositifs SEED d'entrée/sortie.	236
4.2 Les circuits de commande des modulateurs.	237
4.3 Architecture électronique du processeur élémentaire (PE).	238
4.4 Estimation de la bande passante individuelle (BPO _i).	239
4.5 Estimation du nombre de transistors par PE (QI)	239
4.6 Conclusion	240
5. Démonstrateur en technologie hybride CMOS-SEED.	241
5.1 Introduction	241
5.2 Architecture optique	242
5.3 Bilan optoélectronique	245
5.4 Tableaux de mérite système et performances finales.	256
Conclusion générale	259
ANNEXES	262
Annexe A : Modulateur Spatial de Lumière	263
1. Rappel sur les cristaux liquides ferroélectriques	263
2. Caractérisation des SLM.	264
3. Angle de tilt mesuré et contraste maximal	266
Annexe B : Hologrammes synthétiques pour la convolution optique.	270
1. Introduction	270
2. Modélisation.	271
3. Résultats de la synthèse.	274
4. Réalisation des réseaux.	277
5. Résultats expérimentaux.	281

Annexe C : Description des séquences de mouvement	284
1. Introduction	284
2. Séquences Synthétiques.	285
3. Séquences réelles	292
Annexe D : Interface informatique	298
1. Introduction	298
2. Jeu d'instructions sous plate-forme MATLAB.	299
3. Programmes de mise en route	302
4. Programmes de démonstration	303
Références bibliographiques	306

Introduction

L'Ordinateur Optique¹, utopie peut-être aussi fascinante pour cette fin de siècle que l'ont été les ordinateurs mécaniques universels proposés par Charles Babbage dans la première moitié du XIX^e, encourra peut être le même sort que ces lourdes machines face à la technologie des électrons : ils ne verront peut être jamais la lumière du jour (en dehors du laboratoire). Mais, à la différence de ces engrenages qui savaient calculer et qui ne trouveront jamais de place dans un ordinateur de bureau ou de poche, la lumière aura laissé une empreinte indélébile dans le domaine des calculateurs. Tant et si bien qu'il se pourrait que l'ordinateur de demain soit obligé de porter des lunettes – ou pour le moins des microlentilles.

En effet, si dans la communauté des opticiens l'expression présomptueuse "d'Ordinateur Optique" s'estompe, c'est au profit d'un nouveau leitmotiv : on parle désormais de "fonctions optiques dans l'ordinateur" [Chavel87]. Les tenants du traitement tout optique de l'information auraient-ils accepté la défaite ? Ou peut-être, bien plus qu'une tentative pour sauver la mise, l'expression rendrait compte d'une situation technologique nouvelle (ou plutôt de l'effondrement d'une barrière technologique ancienne) au profit de deux communautés, celle des opticiens et celle des électroniciens. En tous cas, la préoccupation n'est plus pour les premiers de faire *mieux* que l'électronique, mais de faire *avec*, et la question que les chercheurs se posent est désormais *comment* : comment *réussir au mieux* ce mariage optoélectronique. Car l'enjeu est énorme : il s'agit de tracer aujourd'hui les grandes lignes de la technologie des ordinateurs du futur.

¹ Par "Ordinateur Optique" ou par "système de traitement *tout optique* de l'information" nous voulons signifier ici tout système de traitement de l'information ayant recours à la lumière (en espace libre ou guidée) pour matérialiser le circuit de données et pour réaliser le traitement lui-même (de nature analogique ou digital, grâce à des matériaux présentant des fortes non-linéarités optiques). Remarquons que l'expression "traitement optique de l'information" a été initialement réservée aux expériences de filtrage de fréquences spatiales sur des images par voie optique (ou "optique de Fourier"), domaine qui connut un essor considérable dès les années 1960 avec l'association de l'holographie et du laser [Goodman68].

L'électronique peut-elle encore faire mieux ?

La puissance des ordinateurs électroniques ne cesse de croître depuis les premiers prototypes datant des années 40 ; le taux de croissance - exponentiel - est d'environ un ordre de grandeur tous les cinq ans². Cet exploit est à attribuer aux énormes progrès de la micro-électronique, qui ont permis de réduire considérablement la taille des transistors dans les circuits MSI, LSI, VLSI et aujourd'hui GSI (pour *Medium, Large, Very Large et Giga Scale Integration* – soit plus d'un milliard de transistors par puce!), sans engendrer une augmentation significative du coût de production. La taille du transistor détermine sa vitesse de *commutation* ; la longueur du canal du transistor MOSFET avoisine aujourd'hui le dixième de micron, et la limite théorique de 0,03 μm en dessous de laquelle le courant électronique engendré par *effet tunnel* sera comparable aux autres courants du transistor n'est plus très loin [Mead94] - il faudra alors modifier la conception ou même le principe sur lequel repose le fonctionnement du transistor. Néanmoins, la technologie CMOS (toujours préférée aux autres technologies numériques pour présenter une consommation électrique très faible) permettra encore de maintenir constante la montée en puissance des microprocesseurs au moins pour la décennie à venir. Si l'on croit aux prévisions - sérieuses - dans le domaine [SIA97], d'ici un an les microprocesseurs commerciaux intégreront jusqu'à 40 millions de transistors sur une surface d'environ 25x34 mm² et seront cadencés à plus de 1,5 Ghz et dans dix ans ils auront dépassé le milliard de transistors par puce (25x44 mm²) et fonctionneront à 3 GHz (pour une étude des limitations fondamentales de la technologie électronique du silicium, voir [Meindl95]).

Malheureusement, le chemin vers ces cimes de performance pour la technologie CMOS est semé d'embûches, et nécessite encore un énorme effort de recherche. En effet, s'il est vrai que le rétrécissement des circuits intégrés a comme effet de réduire la durée de commutation des portes logiques, le délai de propagation du signal *entre* ces portes reste par contre sensiblement constant³. Aujourd'hui ces deux durées sont du même ordre de grandeur (dixième de nanoseconde), et la réduction des circuits électroniques n'entraîne plus à elle seule une amélioration des performances *on-chip*. Plusieurs solutions sont explorées aujourd'hui, comme par exemple le remplacement des interconnexions métalliques en aluminium par du cuivre (de conductivité électrique plus grande), et/ou l'utilisation de nouveaux diélectriques (pour diminuer la capacité entre fils conducteurs) ; à moyen et long terme on pourra avoir recours à des matériaux supraconducteurs à haute température, à des techniques d'intégration "3D" de puces et enfin, à des interconnexions optoélectroniques *intra-chip* [Guilfo96].

² Suivant la loi empirique de Moore [Moore91], l'évolution de la puissance des microprocesseurs augmente d'un facteur 1,6 par an.

³ le délai de propagation du signal dans le fil métallique est proportionnel au produit de sa résistance électrique par la capacité qu'elle forme avec les conducteurs voisins ; or, quand le conducteur métallique s'amincit, sa capacité diminue mais sa résistance augmente.

La conception des *systèmes* électroniques multi-processeurs pose un problème plus urgent. En effet, les performances globales d'un tel système sont sérieusement limitées par le goulot d'étranglement (bande passante insuffisante) *entre* puces d'une même carte. La *Semiconductor Industry Association* [SIA97] prévoit qu'il faudra pouvoir disposer, d'ici un an, d'une bande passante *inter-processeur* dépassant le Tbit/s, avec un nombre de connexions électriques d'entrée-sortie (ou *pins*) par puce dépassant le millier en 2001 (ce qui correspond à des lignes d'entrées-sorties cadencées à plus d'un Gbit/s). Le nombre de pins par puce est limité par des raisons d'encombrement, mais surtout de topologie parce que le bus d'interconnexion inter-processeur est unidimensionnel (*pin-bottleneck*). Pour pallier à un nombre insuffisant de pins par puce, il faudrait disposer d'une très grande bande passante individuelle ; or il s'avère justement que ces interconnexions inter-processeur (ou *inter-chip*) sont relativement longues (dizaine de centimètres), ce qui limite leur bande passante à quelques centaines de MHz.

Les avantages de l'optique

Le recours à l'optique permettrait en théorie de dépasser la plupart des limitations de l'électronique citées ci-dessus. Tout d'abord, en ce qui concerne les éléments de base (portes logiques et/ou mémoires⁴), on a le choix entre un grand nombre de matériaux optiques à réponse non linéaire (matériaux photoréfractifs, matériaux semi-conducteurs de la famille III-V, massif ou en puits quantiques multiples, etc.). Cependant, il ne saurait être question aujourd'hui de rivaliser avec plus de trente ans d'expérience dans l'intégration des composants. Ainsi, dans l'immédiat, la technologie optoélectronique ne permet pas l'intégration massive d'éléments de commutation optiques ayant des caractéristiques suffisamment stables et uniformes.

En fait, les interconnexions optiques constituent le fer de lance de l'optique dans les systèmes de traitement de l'information, l'exemple le plus évident étant l'irremplaçable fibre optique dans le domaine des télécommunications (ou même à l'intérieur des super-ordinateurs). En effet, l'optique peut aider à résoudre le problème du goulot d'étranglement, tout d'abord en ce qui concerne les interconnexions *inter-processeur* dans les architectures multiprocesseurs, et plus tard pour les interconnexions *intra-processeur*. (voir *fig.0.1*). Ceci est possible car les interconnexions optiques présentent des avantages (décisifs) par rapport aux interconnexions électroniques :

- Bande passante de l'interconnexion individuelle bien plus large que celle des conducteurs métalliques, mais surtout indépendante de la longueur de l'interconnexion (dans le cas des interconnexions en espace libre). Ceci permet d'interconnecter aussi bien des processeurs ou cartes éloignées que des puces adjacentes dans une même carte,

⁴ un élément bistable (codant un *bit* mémoire) est réalisé grâce à l'utilisation conjointe d'une non linéarité et d'une rétroaction (par exemple matériau non linéaire dans une cavité résonnante).

séparés de quelques centimètres ou "empilés" les uns sur les autres, en facilitant dans ce dernier cas la dissipation thermique des circuits électroniques.

- Absence de *support matériel* d'interconnexion (pour les interconnexions en espace libre), et absence d'interférence (inter-modulation ou diaphonie) entre différents canaux optiques, ce qui permet un très grande densité d'interconnexion avec la possibilité d'entrecroiser les chemins optiques dans l'espace. La densité d'interconnexion accessible grâce à l'optique en espace libre apporte un niveau de parallélisme très important (exploité dès les débuts de l'optique de Fourier). Par ailleurs, l'absence de support matériel particulier pour la propagation des signaux permet de modifier à dessein la topologie d'interconnexion, grâce à des éléments de commutation reconfigurables placés en un point unique du chemin optique (éléments diffractifs à base de cristaux liquides, modulateurs acousto-optiques, etc.).

Nous pouvons maintenant nuancer l'affirmation faite en introduction : l'Ordinateur Optique n'est pas une utopie au même titre que ne l'ont été les calculateurs mécaniques, car s'il est vrai que dans les deux cas il est question d'un savoir faire très éloigné de l'électronique, le recours à l'optique ne présente que des avantages - dans le domaine des interconnexions, et le stockage de données (mémoire de masse, mais aussi mémoire "vive"[Chuang98])⁵. L'énorme effort de recherche qui sera nécessaire pour son développement est donc totalement justifié (ce qui n'est certainement pas le cas pour les engins mécaniques) - et le restera aussi longtemps qu'il n'existe dans une avenir proche de technologie dépassant théoriquement les possibilités offertes par l'Optique (à l'heure actuelle, les ordinateurs moléculaires, "biologiques" - à ADN - ou quantiques ne constituent pas de concurrents réalistes). Il est vrai pourtant que l'énorme inertie technologique engendrée par plus de quarante ans d'expérience dans le domaine des circuits électroniques rend très difficile l'acceptation brutale de systèmes tout optiques de traitement de l'information dans un monde saturé d'électronique. Il incombe aux chercheurs dans le domaine de convaincre la communauté des ingénieurs des avantages potentiels de l'optique dans l'ordinateur, par exemple à travers la réalisation de prototypes de démonstration peu coûteux mais néanmoins capables de concurrencer (au moins dans une certaine tâche spécifique) les calculateurs électroniques les plus performants. De leur côté, les ingénieurs concepteurs de systèmes électroniques sont aujourd'hui naturellement intéressés par toute alternative permettant de pallier les limitations de l'électronique; ils sont prêts à introduire - petit à petit - quelques fonctions optiques dans l'ordinateur, en sacrifiant dans un premier abord les performances idéales du tout optique au profit de la compatibilité des différents sous-systèmes (un exemple est le remplacement progressif des mémoires de masse magnétiques par des mémoires optiques, reliés aux autres unités

⁵ Théoriquement, les performances d'une porte logique tout optique (signaux d'entrée, de sortie et de contrôle *optiques*) ne dépassent pas celles des portes électroniques (à condition de distinguer la durée de commutation du transistor "seul" de la durée de charge des capacités des fils d'interconnexion). En tout cas, une unité logique tout optique éviterait le recours à des éléments de transduction optoélectroniques.

de l'ordinateur par un bus électronique standard ; à terme on pourrait envisager le remplacement de la mémoire vive par une mémoire optique directement accessible sur les puces optoélectroniques [Chuang98]).

Une époque charnière pour l'optoélectronique?

Une conjoncture technologique favorable facilite et accélère aujourd'hui le processus d'intégration de l'optique dans l'ordinateur ; en voici quelques éléments clés permettant de comprendre cette situation :

- Les énormes progrès de l'optoélectronique ont permis de développer des sources laser puissantes, compactes, et bon marché. Il s'agit des diodes laser à semi-conducteur, pouvant être modulés jusqu'à 30 GHz et dont la puissance à l'unité dépasse facilement la centaine de mW.
- L'exploitation avantageuse de l'optique comme moyen d'interconnexion *entre* systèmes électroniques est bien évidemment conditionnée à la maîtrise de dispositifs de transduction optoélectroniques performants (bande passante $> \text{Gb/s}$), capables de convertir les signaux électriques en signaux optiques et vice-versa, *compatibles* avec la technologie électronique intégrée VLSI (densité de transducteurs > 1000 par puce). C'est (presque) chose faite grâce aux énormes progrès des technologies d'assemblage monolithique ou hybride, permettant l'intégration sur un circuit intégré de matrices de composants optoélectroniques (on parle alors de circuits OE-VLSI) comme par exemple des modulateurs à puits quantiques, de lasers à cavité verticale, etc.. Désormais, le développement des technologies micro-électroniques profite également à l'optoélectronique.
- Jusqu'aux années 1970, la recherche dans le domaine gravite autour de l'optique de Fourier, en privilégiant l'aspect analogique et continu du signal et du traitement [Goodman91]. Une grande diversité d'architectures sont alors proposées et démontrées, parfois dédiées (traitement d'images, reconnaissance de formes par corrélation, traitement acousto-optique du signal radar, etc.), tantôt à prétention plus générale (transformée de Fourier, produit vecteur \times matrice analogique) [McAula91]. Cependant, un système de traitement analogique est délicat à mettre en place, manque de flexibilité, est limité en précision et est peu robuste par rapport à son analogue digital ; ces quelques raisons suffisent à expliquer que dans l'univers de l'électronique le "tout numérique" - traitement et stockage de données - ait d'ores et déjà gagné la bataille par rapport à des solutions analogiques dédiés parfois plus élégantes et/ou simples. Pour ce qui est de l'optique, les *avantages du calcul numérique* se retrouvent alliés au *parallélisme* inhérent à l'optique dans les architectures à base de matrices de pixels intelligents interconnectés en espace libre (SPA, pour *Smart Pixels Arrays* [Hinton97] ou encore OCP dans le cas particulier des *Optical Cellular Processors* [Taboury88]). On peut montrer qu'une telle architecture permet en principe d'homologuer n'importe

quel montage optique analogique (certains parlent alors d'"optique de Fourier digitale" [Ozaktas96]). Ainsi, l'interaction entre l'optique et électronique est aujourd'hui renforcée par l'intérêt que les chercheurs portent sur les architectures optiques "digitales", interaction qui se voit matérialisée dans les matrices optoélectroniques bidimensionnelles à entrées et/ou sorties optiques pour le traitement du signal.

A court terme il apparaît donc que la contribution la plus intéressante de l'optique dans l'ordinateur se situe dans le domaine des interconnexions digitales en espace libre (ou *FSOI* -pour *free space optical interconnects*) entre processeurs ou cartes électroniques, interconnexions qui peuvent être reconfigurables, invariantes ou semi-invariantes par translation [Jenkin84]. Il est vrai pourtant que ces architectures n'exploitent que très discrètement les possibilités de l'optique (qui se limite à résoudre le problème des interconnexions) ; par ailleurs, et comme expliqué plus haut, les performances globales de ces systèmes restent étroitement liées à celles des dispositifs de transduction optoélectronique. Un grand nombre de prototypes a été proposé et réalisé, concernant des domaines aussi éloignés que le sont le traitement des images (en temps réel) et la commutation de paquets ATM par exemple ; le point commun entre tous ces systèmes est l'exploitation du parallélisme spatial (ou multiplexage spatial) fourni par les interconnexions optiques en espace libre.

Notre recherche sur les processeurs optoélectroniques

Il existe pourtant quelques domaines où l'optique *analogique* fait (ou peut potentiellement faire) mieux que l'électronique. La corrélation et la transformée de Fourier optique en sont les exemples les plus connus (corrélateurs temps réel pour la reconnaissance de formes et/ou le suivi de cibles [Colin98], formation d'images SAR en temps réel [Haney98]) ; les réseaux de neurones constituent un autre domaine où l'optique peut potentiellement faire mieux que l'électronique (le stockage en volume des poids synaptiques analogiques dans un cristal photoréfractif offre des possibilités théoriques extraordinaires encore à démontrer expérimentalement). Nous allons explorer dans cette thèse un autre créneau intéressant pour l'optique analogique - à notre connaissance très peu exploitée - à savoir la possibilité de générer très rapidement et par voie optique un échantillon très large de nombres aléatoires (aux propriétés statistiques bien contrôlées) sur un circuit VLSI [Lalann95]. La génération de nombres aléatoires trouve des applications dans des domaines très divers, comme par exemple les méthodes d'optimisation stochastique de type Monte Carlo, la simulation des réseaux de neurones, et le cryptage de données.

<u>Éléments mis en liaison (nœuds)</u>	<u>Dispositif optique</u>	<u>Maturité technologique</u>	<u>Nature de l'interconnexion</u>
<p>Ordinateurs et systèmes (<i>system-level</i>)</p> <p>Unités de calcul, de stockage, etc. (<i>cabinet-level</i>)</p>	<p>Fibres optiques</p> <p>Nappe de fibres optiques (ex : OPTOBUS™ [OPTOBUS])</p>	<p>Compatible avec la technologie standard (fibres optiques, diodes lasers, composants discrets)</p>	<p>1) A travers un <i>système</i> plus ou moins complexe</p> <p><u>Commutateurs</u> par paquets ou de circuits, à contrôle distribué ou centralisé, synchrone ou non (protocoles très divers, ATM, Ethernet CSMA, etc. - [Koppa95])</p>
<p>Cartes électroniques (PCB -<i>printed circuit boards</i>) ou modules multi-chips (MCM) d'une même unité (<i>board-level</i>)</p>	<p>Optique en espace libre (FSOI -<i>free space optical interconnection</i>) pour réaliser des « Optical (intelligent) backplanes » utilisant des SPA -<i>Smart Pixels Arrays</i>.</p>	<p>Compatible <i>court terme</i> avec la technologie VLSI standard (recherche sur les interfaces d'E/S optoélectronique parallèles)</p>	<p><u>Bus optique</u> 2D reconfigurable de type cross-bar [SPOEC], token ring [TRANSPAR], etc.</p>
<p>Puces* d'une même carte (<i>inter-chip-level</i>)</p>	<p>Optique intégrée, fibres optiques laminiées [Li99], connecteurs 2D à fibres optiques en PMMA (poly-méthyl-méthacrylate) [Jöhnck99].</p>	<p>Nouvelles technologies optoélectroniques et micro-optiques compatibles VLSI en développement</p>	<p>2) Liaison « passive », plus ou moins directe</p>
<p>Éléments d'une même puce (<i>intra-chip-level</i>)</p>	<p>Macro et micro-optique en espace libre (microlentilles, DOE) et optique planeaire [Sinzin98].</p> <p>Micro-optique, micro-mécanique (ex : ponts optiques en PMMA [Versch98])</p>		<p>Interconnexion dense et fixe entre puces adjacentes (point-to-point, fan-in, fan-out) - par exemple le <i>perfect shuffle</i> [Stone71].</p> <p>Interconnexions fixes point à point.</p>

Fig.0.1 : pénétration de la technologie optique au cœur des systèmes de traitement de l'information par le biais des interconnexions optiques. (* Il peut s'agir d'éléments dédiés exclusivement à la transduction optoélectronique (matrices de VCSELs par exemple), ou à la transduction et au traitement du signal (Smart Pixels Arrays) pour la reconnaissance et le routage des données (brique de base des « interconnexions intelligentes »), ou capables d'opérations plus ou moins complexes et variées (opérations logiques élémentaires permettant à terme de construire une ULA pour un calculateur à usage général, ou calculs dédiés de type DSP - convolution et FFT digitale, traitement d'images, tri de données, etc.).

La génération optique de nombres aléatoires permet non seulement d'alléger la conception du circuit électronique (générateur pseudo-aléatoire), mais présente également une plus large bande passante, est facilement exploitable en parallèle, et est théoriquement une source de meilleure qualité (car basée sur un véritable phénomène physique aléatoire).

Le travail de thèse qui sera décrit par la suite s'inscrit dans la continuité des travaux dans le laboratoire sur les *réтины artificielles stochastiques*. Il s'agit d'un domaine de recherche à l'entrecroisement de l'optique, de l'électronique et du traitement du signal ; plus précisément, il s'agit d'un lieu résultant de la convergence de deux fronts de recherche : l'algorithmique pour le traitement d'images d'une part [Geman84], et l'étude d'architectures optoélectroniques cellulaires [Tabour88] de l'autre. La *fig.0.2* permet de visualiser les ponts que l'on peut établir entre les divers *aspects algorithmiques* de cette recherche et leur implantation matérielle grâce à des *fonctions optiques*. Le produit final de cette interaction est une *rétine artificielle stochastique optoélectronique* [Lalann93] capable de traiter un certain nombre de problèmes en traitement d'images bas niveau. Nous allons étudier un cas particulier d'une telle rétine, auquel nous référerons par *Processeur Parallèle Optoélectronique Stochastique* (PPOS en abrégé).

Plusieurs objectifs sont poursuivis dans cette thèse :

☞ **Etude de processeurs optoélectroniques dédiés analogiques et digitales :** recherche sur les aspects algorithmiques et architecturaux de processeurs parallèles opto-électroniques stochastiques (PPOS) pour le traitement d'images bas-niveau. Ces circuits VLSI se présentent sous forme de matrices de processeurs élémentaires (PE) possédant des entrées optiques analogiques. Ils permettent la mise en œuvre parallèle des méthodes de recuit simulé en utilisant du speckle laser comme générateur de nombres aléatoires.

☞ **Construction d'un prototype de démonstration complet.** Il s'agit de démontrer la possibilité d'intégrer ce genre de processeur dans une chaîne de traitement d'images fonctionnant à cadence vidéo. L'exemple retenu pour la démonstration est la détection du mouvement en temps réel.

☞ **Etude d'un montage à interconnexions optiques holographiques inter-processeur** (CLF/CI-PPOS) permettant de simuler des interconnexions reconfigurables *intra-processeur* entre les différents PEs du PPOS (cet étude concerne les niveaux les plus en amont de la recherche sur les interconnexions optiques – deux derniers échelons du tableau *fig.0.1*).

☞ **Analyse des performances théoriques d'un nouveau processeur en technologie hybride OE-VLSI** (entrée et sortie optique permettant une véritable interconnexion optique *intra-processeur*). Il s'agit d'une étude préliminaire préparant une éventuelle intégration micro-optique de tout le système.

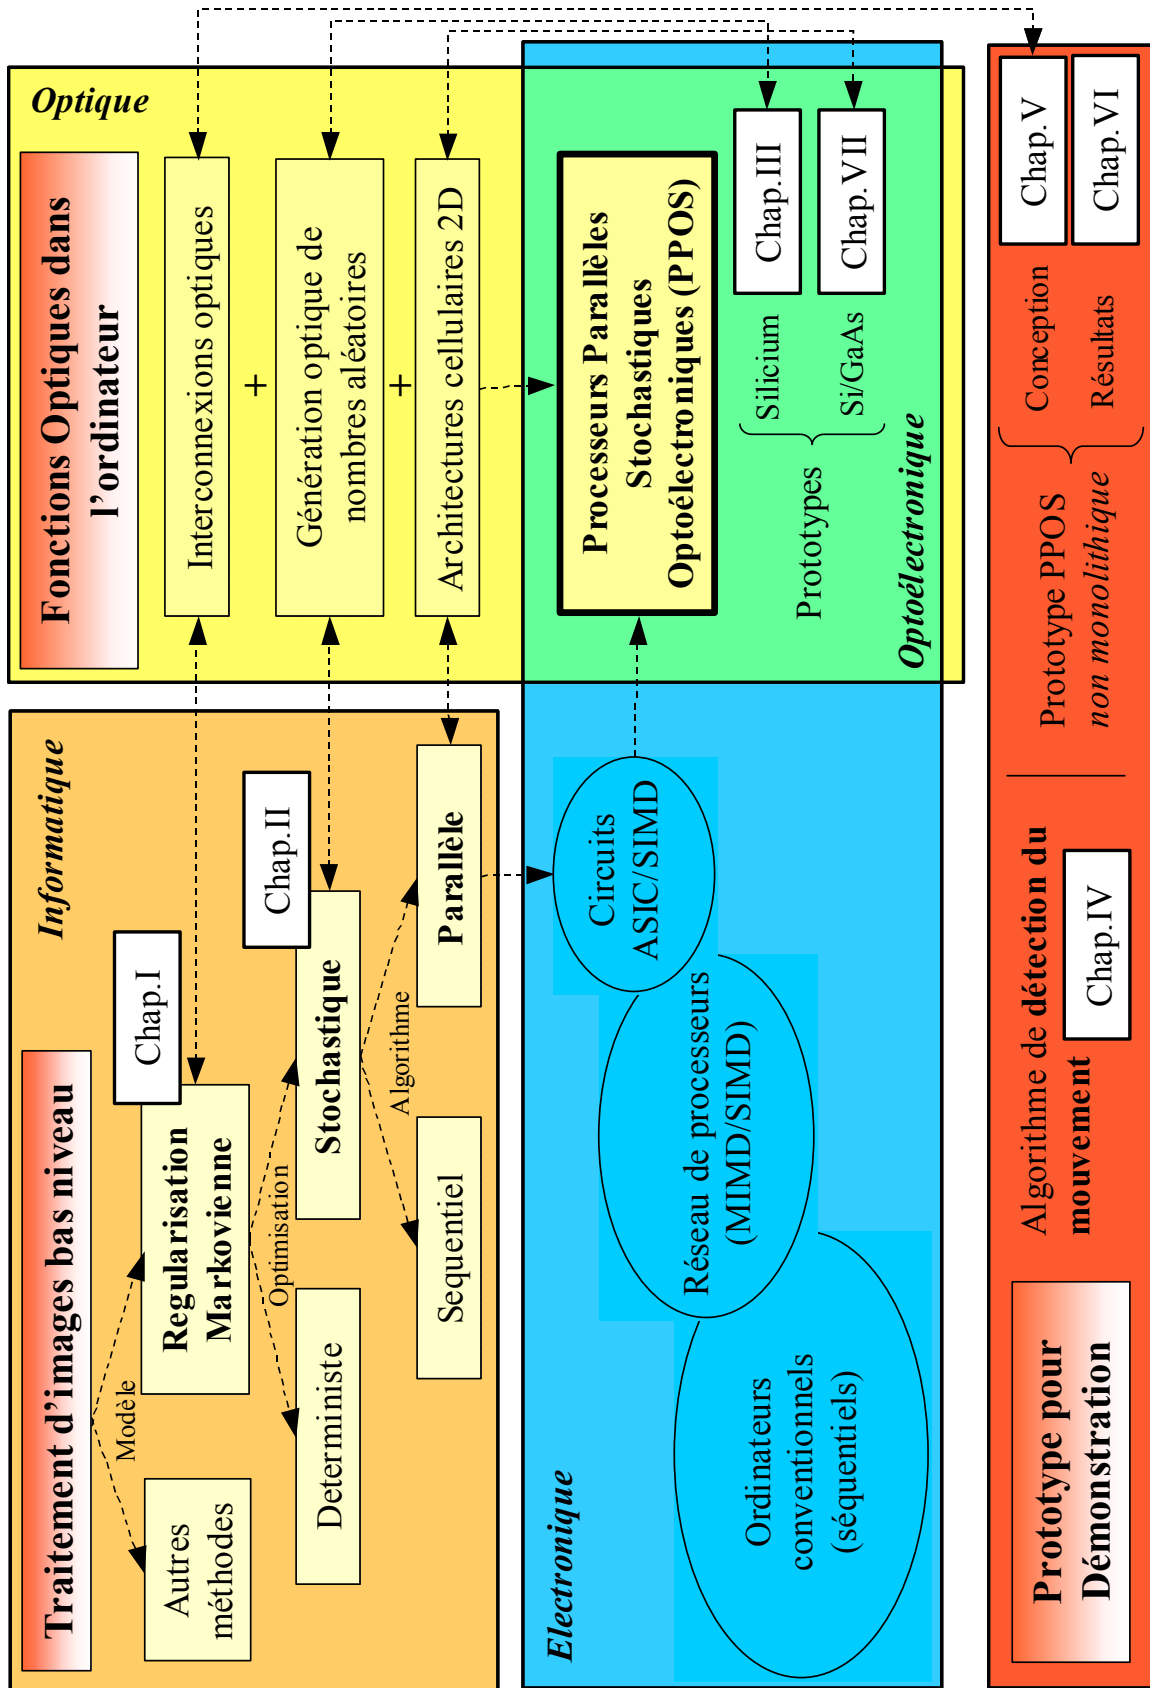


Fig.0.2 : Définition de la "niche technologique" propre à notre recherche sur les processeurs parallèles optoélectroniques stochastiques (PPOS) et correspondance avec le contenu des chapitres de la thèse.

Plan de la thèse.

La *fig.0.2* permet de situer respectivement les différents chapitres de la thèse dans l'ensemble des sujets abordées. Entre ces sujets, on distingue notamment :

A) Les aspects algorithmiques et architecturaux du processeur. Le but des deux premiers chapitres est de préciser le cadre mathématique de notre recherche sur les processeurs parallèles optoélectroniques stochastiques pour le traitement d'images. Le **chapitre I** introduit la notion de régularisation bayésienne par champ de Markov en traitement d'images bas-niveau ; quelques exemples concrets sont présentés en fin du chapitre. Le **chapitre II** traite plus particulièrement des algorithmes d'optimisation stochastiques utilisés pour résoudre en pratique le problème de régularisation (recuit simulé), et discute des possibilités de parallélisation des algorithmes (recuit simulé parallèle). A la fin du chapitre, les diverses propriétés requises pour réaliser une machine spécialisée dans le traitement d'images par recuit simulé sont présentées sous la forme d'un cahier de charges.

B) L'optoélectronique pour le recuit simulé. Un premier prototype de Processeur Parallèle Optoélectronique dédié à l'optimisation Stochastique (PPOS) fait l'objet **chapitre III**. Le processeur (appelé SPIE600) est réalisé en technologie VLSI-CMOS 0,8 μ m sur silicium. Il s'agit d'une machine-tableau à *interconnexions électriques non reconfigurables*. Le rôle de l'optique y est limité à la génération de nombres aléatoires permettant de mener à bien le calcul d'optimisation stochastique (recuit simulé).

C) Le démonstrateur pour la détection du mouvement. Le **chapitre IV** reprend les concepts avancés au chapitre I pour étudier l'exemple particulièrement intéressant de la détection du mouvement. Divers algorithmes sont présentés et discutés ; en fin de chapitre nous dégagerons un algorithme simplifié susceptible d'être implanté dans un démonstrateur construit autour de SPIE600. La conception d'un système optoélectronique complet à *interconnexions optiques reconfigurables*, exploitant les capacités du processeur SPIE600 est présenté dans le **chapitre V**, mais la boucle de rétroaction des données est *non monolithique* et comporte un modulateur à cristaux liquides ferroélectriques sur circuit intégré (CLF/CI). Les résultats expérimentaux et la démonstration finale de la détection du mouvement sont présentés au **chapitre VI**.

D) Exploration des nouvelles technologies optoélectroniques. Au **chapitre VII** nous étudierons la possibilité de réaliser un prototype de PPOS à entrée et *sortie* optiques en technologie *hybride* CMOS-SEED ; la puissance de calcul est considérablement améliorée, grâce à la rétroaction monolithique des données (l'architecture étudiée comporte de véritables interconnexions optiques *intra-processeur*).

F) Enfin, une brève **conclusion générale** permettra de commenter les résultats obtenus et d'en discuter la portée par rapport aux objectifs que nous nous sommes fixés au paragraphe précédent.

Chapitre I

Champs de Markov en analyse d'images

1. Introduction

La recherche sur les machines de vision est menée parallèlement sur deux fronts : le premier est fortement pluridisciplinaire, et l'on trouve des spécialistes en mathématiques appliquées travaillant en étroite collaboration avec des neurobiologistes et des cognitivistes pour tenter d'appréhender les mécanismes de vision biologiques résultant d'une très longue évolution naturelle. Des ingénieurs tentent ensuite de reproduire artificiellement - avec plus ou moins de bonheur - quelques fonctions du système de vision biologique (on parle de systèmes *neuromimétiques*). La deuxième approche est plus abstraite et mathématique. Elle est généralement désignée par l'expression *vision artificielle* et consiste à considérer les images comme des *signaux* pour en extraire des *primitives* à l'aide d'algorithmes appropriés.

Etant donnée l'efficacité des systèmes de vision naturels, la première démarche semble a priori très prometteuse. Cependant, malgré la recherche en neurobiologie qui avance à pas de géant, la compréhension des mécanismes intervenant dans la vision des vertébrés est loin d'être complète (voir *fig.I.1*). Les espoirs sont finalement déçus : à l'heure actuelle, on peut dire que seule la fonction de capteur d'images est très correctement reproduite artificiellement ; mais même dans ce cas, c'est sans compter avec le système d'asservissement automatique de la focale du cristallin (*accommodation*), ou le mécanisme de compression logarithmique qui vaut à l'œil humain l'incroyable exploit d'une dynamique pouvant couvrir de 8 à 10 ordres de grandeur. Par ailleurs, les composants biologiques à la base des systèmes de vision biologiques (ou *wetware*) ne trouvent pas d'équivalent simple (et/ou bien maîtrisé) en technologie électronique, et surtout pas en électronique *numérique*⁶.

⁶ Le traitement de l'information par le système nerveux se fait selon des principes totalement étrangers aux techniques numériques familières aux ingénieurs. Le signal n'est pas traité de manière digitale et les opérations de base ne sont pas booléennes : le système nerveux exploite *directement* les phénomènes




Fig.I.1 : Une bonne partie du cerveau des vertébrés supérieurs - un tiers du cortex chez l'humain - est consacrée à des tâches relatives à la vision (aires grisées dans la figure, représentant un cerveau de macaque). Bien que la "cartographie" des circuits neuronaux impliqués dans la vision soit aujourd'hui extrêmement précise (circuit superposé), la compréhension des principes et mécanismes sous-jacents est loin d'être complètement élucidée. Représentation simplifiée et volontairement 'artistique' à partir de [Essen92].

En revanche, la recherche en vision artificielle évolue plutôt au rythme des progrès de l'informatique et de la recherche en traitement du signal. De nombreux algorithmes qui ont fait leurs preuves ont vu le jour depuis quelques années. L'avantage de cette approche réside surtout dans le fait que l'on peut procéder par étapes, en posant à chaque fois le problème en termes mathématiques. La puissance de ces algorithmes reste cependant liée à la rapidité des machines plus ou moins classiques sur lesquelles ils s'exécutent. Une des étapes *critiques* de la vision artificielle - extrêmement gourmande en calcul - est celle que l'on appelle vision *bas-niveau* (*early vision* en anglais). Dans cette étape on s'intéresse à l'extraction des toutes premières primitives de l'image brute : le programme est confronté à un flot de données énorme et doit faire le tri très vite entre le pertinent et l'accessoire pour que l'information soit accessible en *temps-réel*⁷. Tout comme dans les

physico-chimiques élémentaires de ses "composants" comme primitives de calcul, alors que l'ordinateur conventionnel ne profite des non-linéarités des transistors que de façon très frustrée, par l'opération de seuillage [Mhani97].

⁷ On dit qu'un système de traitement est *temps-réel* (*real-time*) quand les résultats sont obtenus en un temps déterminé, indépendamment des caractéristiques particulières de l'échantillon de données à traiter - autrement dit, le flux de données de sortie correspond au flux de données d'entrée à un décalage temporel constant près. Ce temps dépend uniquement du domaine d'application (1 ms pour l'optique adaptative, 10 ms pour le suivi de missiles, 100 ms pour l'aide à la conduite, etc.).

systèmes biologiques, il s'opère dans cette étape une réduction considérable de l'information⁸ qui aboutit à des représentation abstraites très simples du contenu de l'image ou *primitives*, représentations fragmentaires et pas immédiatement reliées entre elles (contours [Koch86], régions et textures [Geman84], champs de mouvement [Poggio85], [Heitz92], profondeur des objets en stéréovision [Marroq87], etc.). A partir de là, des fonctions cognitives supérieures prennent tour à tour le relais, en fusionnant ces données à l'aide de modèles a priori plus ou moins complexes dans le but ultime de construire une représentation *haut niveau* du monde extérieur.

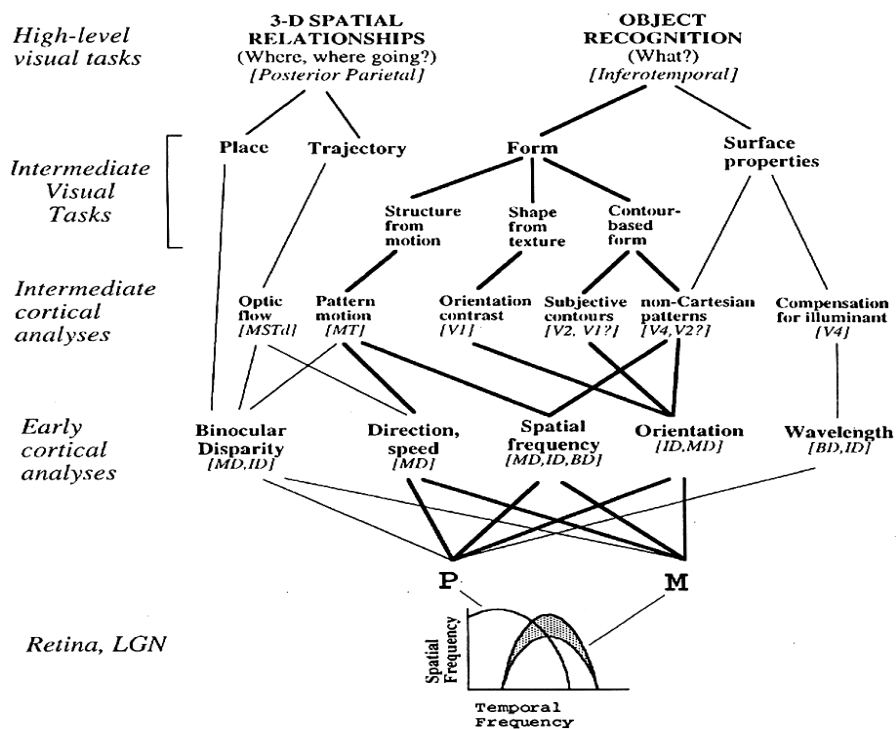


Fig.I.2 : Modularité et hiérarchie dans le système de vision biologique, et relation avec les aires visuelles du cerveau humain. Pour détails, voir [Essen92].

Remarquons enfin que l'approche biologique recoupe l'approche mathématique au moins en deux points. Tout d'abord, le système de vision des vertébrées est lui aussi structuré de façon hiérarchique et modulaire (voir fig.I.2). Par ailleurs, certaines approches statistiques en vision artificielle *bas niveau* conduisent à des modèles tout à fait équivalents aux systèmes connexionnistes biologiques (réseaux de neurones d'un côté et régularisation bayésienne par champs de Markov de l'autre). C'est à ces modèles statistiques que seront consacrés les deux premiers chapitres de cette thèse.

⁸ Il est intéressant de remarquer que la rétine (de l'homme) possède plus d'une centaine de photorécepteurs (cônes et bâtonnets) pour une seule fibre nerveuse de sortie dans le nerf optique.

2. Régularisation Bayésienne

2.1 Introduction et notations

L'extraction de primitives de l'image en vision bas niveau est en général un problème *mal posé* au sens d'Hadamard [Berter88], i.e., pour une donnée unique du problème, il existe plusieurs solutions possibles compatibles avec l'observation. L'introduction d'un certain nombre de contraintes permet de restreindre l'ensemble des solutions. Cette technique de tri *a priori* porte le nom de *régularisation*. Par rapport à la régularisation standard, qui met définitivement de côté un sous-ensemble de solutions, la régularisation bayésienne est une approche *probabiliste* : le problème est modélisé de telle sorte qu'une distribution de probabilités pondérant chacune des solutions potentielles est construite sur l'ensemble des solutions possibles.

Les notations suivantes seront appliquées tout au long de la thèse. Leur interprétation concrète dépendra du problème traité :

Le support de l'image (grille de pixels ou sites) :

$S = \{0 \dots n-1\} \times \{0 \dots m-1\}$ ensemble de sites de l'image de taille $n \times m$. $N = mxn$ est donc le nombre de pixels ou sites de l'image. q, r ou $s \in S$ sera la notation usuelle pour un site particulier de l'image. Enfin, $V(s)$ dénotera un ensemble de sites autour de $s \in S$ appelé *voisinage* de s .

L'image (image "réelle" observée par le capteur) :

$I = \{I(s) \in G_I, s \in S\}$ est le champ *image* (considéré comme un champ aléatoire). G_I est un ensemble continu ou discret, fini ou infini de niveaux de gris de l'image réelle. Le champ (déterminé) $i = \{i(s) \in G_I, s \in S\}$ représente une image particulière (réalisation du champ image). On notera Ω_I l'ensemble des réalisations possibles du champ image : $\Omega_I = G_I^{n \times m}$.

L'observation (résultat de l'observation de l'image "réelle") :

$O = \{O(s) \in G_O, s \in S\}$ est le champ *d'observation* associé à l'image. G_O est un ensemble continu ou discret, fini ou infini des valeurs possibles pour l'observation. Le champ $o = \{o(s) \in G_O, s \in S\}$ est une réalisation particulière du champ O . On notera $\Omega_O = G_O^{n \times m}$ l'ensemble des réalisations possibles du champ d'observation.

Le champ de primitives ou étiquettes de l'image (choses "à voir") :

$E = \{E(s) \in G_E, s \in S\}$ est le champ *d'étiquettes* ou *primitives* associé à l'image. $e = \{e(s) \in G_E, s \in S\}$ est une réalisation particulière du champ d'étiquettes. $e(s)$ est l'étiquette associée au site s à valeurs dans $G_E = \{a_1, a_2, \dots, a_p\}$, ensemble *discret et fini* des valeurs possibles pour les étiquettes. L'ensemble des réalisations possibles du champ d'étiquettes sera noté $\Omega_E = G_E^{n \times m}$.

On utilisera indifféremment les notations $E(s)$ ou E_s pour caractériser le champ (d'étiquettes en l'occurrence) au site s de la grille S . Dans le cas de traitement spatio-temporels (détection du mouvement par exemple), les champs aléatoires précités doivent être remplacés par des *processus aléatoires* à dimension temporelle (cf.Chap.IV).

2.2 Règle de Bayes

La règle de Bayes est à la base du formalisme. Soit le champ d'observations O issu des données observées et E le champ d'étiquettes que l'on cherche à estimer. La distribution de probabilités sur l'ensemble Ω_E de toutes les réalisations possibles de E connaissant $O=o$ s'appelle *distribution a posteriori* du champ à estimer et s'obtient par la formule de Bayes :

$$\Pr(E = e / O = o) = \frac{\Pr(E = e) \cdot \Pr(O = o / E = e)}{\Pr(O = o)} \quad (\text{Eq.I.a})$$

L'application de la règle de Bayes implique d'une part (a) la possibilité de décrire statistiquement le processus d'observation par la distribution de probabilités $\Pr(O/E)$, et d'autre part (b) la connaissance de la distribution de probabilités *a priori* $\Pr(E=e)$ du champ d'étiquettes. Si ces deux conditions sont remplies, on peut construire à partir de la distribution a posteriori plusieurs estimateurs du champ d'étiquettes recherché ; un *estimateur* \hat{e} est une application associant à toute réalisation du champ d'observation o , une configuration d'étiquettes estimée $\hat{e}(o)$:

$$\begin{aligned} \hat{e} : \Omega_O &\rightarrow \Omega_E \\ o &\mapsto \hat{e}(o) \end{aligned}$$

La *qualité* d'un estimateur est définie par rapport à une distance C sur l'ensemble Ω_E , aussi appelé *fonction de coût*. On appelle *estimateur bayésien optimal* relativement à la fonction de coût C , un estimateur \hat{e} pour lequel l'espérance mathématique de la fonction de coût (ou *risque*) est minimale⁹. Puisque la distribution de probabilité du champ O est positive, l'estimateur bayésien optimal doit minimiser le *risque conditionnel* pour *chaque* réalisation $o \in O$:

⁹ la moyenne porte sur toutes les réalisations *conjointes* possibles de E et de O (le *risque* ainsi défini est une mesure du coût moyen "d'erreur" de l'estimateur) :

$$\begin{aligned} \text{Risque}(\hat{e}) &= \langle C(\hat{e}(O), E) \rangle_{\Omega_O \times \Omega_E} = \int_{o \in \Omega_O} \int_{e \in \Omega_E} C(\hat{e}(o), e) \cdot p_{EO}(o, e) \mu(de) \mu(do) \\ &= \int_{o \in \Omega_O} p_O(o) \mu(do) \int_{e \in \Omega_E} C(\hat{e}(o), e) \cdot p_{E/O}(e / O = o) \mu(de) \end{aligned}$$

(on appelle *risque conditionnel* la valeur de l'intégrale portant sur Ω_E dans l'expression ci-dessus).

$$\forall o \in O, \hat{e}(o) = \arg \min_{\hat{e} \in \Omega_E} \int_{e \in \Omega_E} C(\hat{e}, e) \cdot p_{E/O}(e/O=o) \mu(de)$$

Le choix de l'estimateur dépend du problème considéré. Voici une liste des estimateurs le plus couramment utilisés en traitement des images [Marro85a] :

Nom	Fonction de coût	Expression résultante
Maximum A Posteriori (MAP)	$\forall (a, b) \in \Omega_E \times \Omega_E,$ $C(a, b) = 1 - \delta(a, b)$	$\hat{e}^{MAP}(o) = \arg \max_{e \in \Omega_E} [\Pr(E = e / O = o)]$
Maximum des distributions a Posteriori Marginales (MPM)	$C(a, b) = \sum_{s \in S} (1 - \delta(a_s, b_s))$	$\hat{e}^{MPM}(o) = \{\hat{e}_s^{MPM}, s \in S\},$ avec $\forall s \in S :$ $\hat{e}_s^{MPM}(o) = \arg \max_{g \in G_E} [\Pr(E_s = g / O = o)]$
Estimateur du Champ Moyen (MF)	$C(a, b) = \sum_{s \in S} (a_s - b_s)^2$	$\hat{e}^{MF}(o) = \{\hat{e}_s^{MF}(o), s \in S\},$ avec $\forall s \in S :$ $\hat{e}_s^{MF}(o) = \langle E_s / O = o \rangle_{G_E}.$

2.3 Lien statistique entre observation et étiquettes.

Le terme de probabilité conditionnelle des observations par rapport aux étiquettes $Pr(O=o/E=e)$ dépend de la modélisation du processus d'observation. Le champ observé est censé contenir toute l'information disponible sur l'image (ou la séquence d'images dans le cas de la détection du mouvement). Selon les cas, l'observation est soit directement accessible, soit elle résulte d'un pré-traitement plus ou moins complexe de l'image originale. Il est courant de modéliser le lien statistique entre observation et étiquettes par la relation [Geman84] :

$$\forall s \in S, \quad O(s) = \Phi[F_s(e^*), B(s)], \quad (\text{Eq.I.b})$$

où s appartient à un sous-ensemble de sites de l'image $s \in A \subseteq S$. Dans la formule, e^* représente le champ d'étiquettes réel que l'on cherche à estimer, et $O(s)$ est l'observation (considérée comme une variable aléatoire) au site s . Dans le cas de la restauration d'images, e^* n'est autre que l'image réelle $i \in \Omega_i$ avant d'être corrompue par le bruit, et o est l'image dégradée récupérée par le système d'imagerie –voir exemple plus loin. Le fait que les observations soient définies pour un sous-ensemble A de l'image permet de modéliser le cas de données incomplètes. La fonction F_s qui est typiquement non inversible représente par exemple la réponse impulsionnelle du système d'imagerie. La fonction Φ modélise quant à elle la réponse du détecteur : il s'agit d'une fonction inversible qui couple localement aux observations un bruit de nature aléatoire, noté $B(s)$, avant d'appliquer une transformation locale sans effet mémoire. La fonction Φ peut être

linéaire (cas des caméras CCD) ou non linéaire (logarithmique pour l'œil ou la plaque photo). Le bruit peut être couplé aux mesures de manière additive ou multiplicative. Sa statistique conditionnera directement celle du terme de vraisemblance ; elle peut être, par exemple poissonnienne ou gaussienne, selon la nature du phénomène observé.

A partir de ce modèle, on peut remonter au terme de vraisemblance recherché $\Pr(O/E)$. On a tout d'abord $B(s) = \Phi^{-1}[F_s(e^*), O(s)]$; si le bruit est décorrélé spatialement (i.e. si les variables $B(s)$, $s \in S$ représentent des variables aléatoires indépendantes) alors on peut écrire directement le terme de vraisemblance :

$$\Pr(O = o / E = e) = \prod_{s \in A} \Pr[B(s) = \Phi^{-1}(F_s(e), o(s))]$$

Par la suite on préférera la forme exponentielle :

$$\Pr(O = o / E = e) = \frac{1}{Z} \exp \left[- \sum_{s \in S} \Psi_s(e, o(s)) \right],$$

où l'on a posé de façon formelle :

$$\Psi_s(e, o(s)) = -Z \cdot 1_A(s) \cdot \ln \Pr[B(s) = \Phi^{-1}(F_s(e), o(s))]$$

(Z est une constante arbitraire et 1_A est la fonction caractéristique de $A \subseteq S$). Cette formulation s'avérera utile par la suite car elle fait apparaître la *fonction de coût ou énergie de contrainte aux données observées* $U_{obs}(e, o) = \sum_{s \in S} \Psi_s(e, o(s))$ lors de

l'intégration dans la formule de Bayes (cf. §4.1) :

$$\Pr[O = o / E = e] = \frac{1}{Z} \exp[-U_{obs}(e, o)] \quad (\text{Eq.I.c})$$

Exemple : Restauration d'images dégradées sans prise en compte de bords. Pour fixer les idées, prenons l'exemple plutôt simple de la restauration d'images dégradées sans prise en compte des bords [Geman84]. Dans ce cas, le champ d'observation O s'identifie avec le champ de niveaux de gris de l'image issu d'un système d'acquisition (objectif et caméra CCD par exemple). Le champ d'étiquettes E à reconstruire est tout simplement l'image originale non dégradée.

La fig.I.3 représente les diverses transformations de l'image originale pour aboutir au champ d'observation O . Le processus d'observation est bien modélisé par la formule eq.I.b. Dans le cas très simple d'un système d'imagerie sans flou ($F=I$) et d'une réponse parfaitement linéaire du capteur, l'eq.I.b devient tout simplement : $o = e + n$. Si l'on suppose en outre que le bruit est décorrélé spatialement, et qu'il est sur chaque site gaussien, centré et de variance σ^2 , alors sur l'image entière le terme de vraisemblance s'écrit :

$$\Pr(O = o / E = e) = \prod_{s \in S} \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left(- \frac{(o(s) - e(s))^2}{2\sigma^2} \right).$$

La fonction d'énergie à minimiser est alors (à une constante additive près) :

$$U_{obs}(e, o) = \sum_{s \in S} \Psi(o, e_s) = \frac{1}{2\sigma^2} \sum_{s \in S} [e(s) - o(s)]^2$$

La fonction $\Psi(o, e_s) = \frac{1}{2\sigma^2} (e(s) - o(s))^2$ peut être vue comme un potentiel de clique binaire liant le champ d'observation avec le champ d'étiquettes (voir remarque au §4.1).

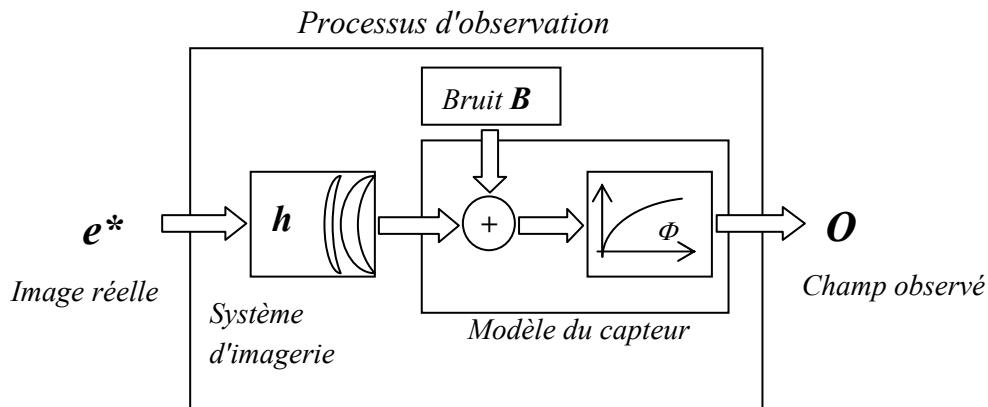


Fig.I.3 : Modèle du processus d'observation (acquisition d'images bruitées).

2.4 Probabilité *a priori* : modèle Markovien spatial.

Si aucune information supplémentaire *a priori* n'est introduite, $Pr(E=e)$ est une constante par rapport à e , et la distribution *a posteriori* issue de la formule de Bayes s'identifie avec le terme de vraisemblance $Pr(O/E)$. Le critère du MAP devient alors tout simplement le critère du *Maximum de Vraisemblance* (MV)¹⁰. Puisque aucune contrainte n'est imposée quant à l'ensemble des solutions possibles du problème, la solution optimale correspond simplement à celle qui s'approche le mieux des données observées : il sera inutile par exemple de traiter par cette méthode la reconstruction d'images dégradées, car l'image observée est elle-même une solution acceptable du problème - et qui plus est, c'est la *meilleure* au sens du MV. Il faut donc introduire des contraintes *a priori* sur les solutions. Un *champ de Markov* en traitement d'images est un champ d'étiquettes à valeurs continues ou discrètes destiné à caractériser les informations sous-jacentes de l'image ou *primitives* (champ de vitesses dans le cas de l'estimation du mouvement, numéro de région dans le cas de la segmentation, etc.). La modélisation par champ de Markov rend compte des propriétés spatiales *a priori* (et/ou spatio-temporelles dans le cas d'une séquence d'images) des images observées. La propriété principale de la

¹⁰ L'estimateur du maximum de vraisemblance maximise la probabilité conditionnelle $Pr(O/E)$, considéré comme fonction de $E=e$ (celle-ci est appelé alors *vraisemblance*).

régularisation par champs de Markov est de conduire à des primitives *homogènes par zones* et automatiquement *débarrassées du bruit* [Geman84]. D'un point de vue formel, la modélisation par champ de Markov présente deux intérêts majeurs : (1) tout d'abord, il s'agit d'un modèle facilement paramétrable ; (2) comme on le verra au paragraphe suivant, à cette souplesse s'ajoute l'avantage d'une formulation immédiate du terme de probabilité conjointe du champ d'étiquettes $Pr(E)$ grâce au théorème de *Hammersley-Clifford* qui relie propriétés locales (marginales) et probabilités globales du champ.

Ce qui suit est destiné à rappeler la terminologie et les fondements de la théorie des champs des Markov aléatoires ou MRF (pour *Markov Random Fields*). Pour plus de détails, voir [Azenco87].

3. Champs de Markov.

3.1 Définitions.

Le but de cette partie est de rappeler les principales définitions et propriétés relatives aux MRF utiles dans le cadre de la régularisation bayésienne. La caractéristique principale des MRF est de fournir un modèle probabiliste *a priori* du champ des primitives à estimer.

Définition. Un champ aléatoire¹¹ E est un *champ de Markov* relativement à un voisinage V si et seulement si la propriété suivante est vérifiée :

$$Pr [E(s)=e(s) / E(r)=e(r), \forall r \in S, s \neq r] = Pr [E(s)=e(s) / E(r)=e(r), r \in V(s)].$$

Ainsi, les propriétés statistiques locales d'un champ de Markov au site s ne dépendent que de l'état d'un voisinage plus ou moins étendu défini autour de ce site et non de l'état du champ tout entier. En traitement d'images bas-niveau, on est en général amené à se contenter de considérer des voisinages d'ordre 1 (4 voisins), d'ordre 2 (8 voisins) ou d'ordre 3 (12 voisins) - voir *fig.I.4*.

Remarque : Cette propriété de localité rend compte des propriétés intrinsèques de l'image, mais elle sera également mise à profit pour le calcul d'optimisation qui pourra être lui aussi local (et donc parallélisable) puisque toute l'information contextuelle à la prise de décision en un point est contenue dans un voisinage assez réduit (*cf.* Chap.II,§2.2.7).

¹¹ En toute rigueur, un champ aléatoire est défini par le triplet $(\Omega_E, \mathcal{F}, P)$, où l'espace des configurations du champ Ω_E est muni d'une tribu \mathcal{F} et d'une mesure de probabilité P (mesure positive et de masse 1).

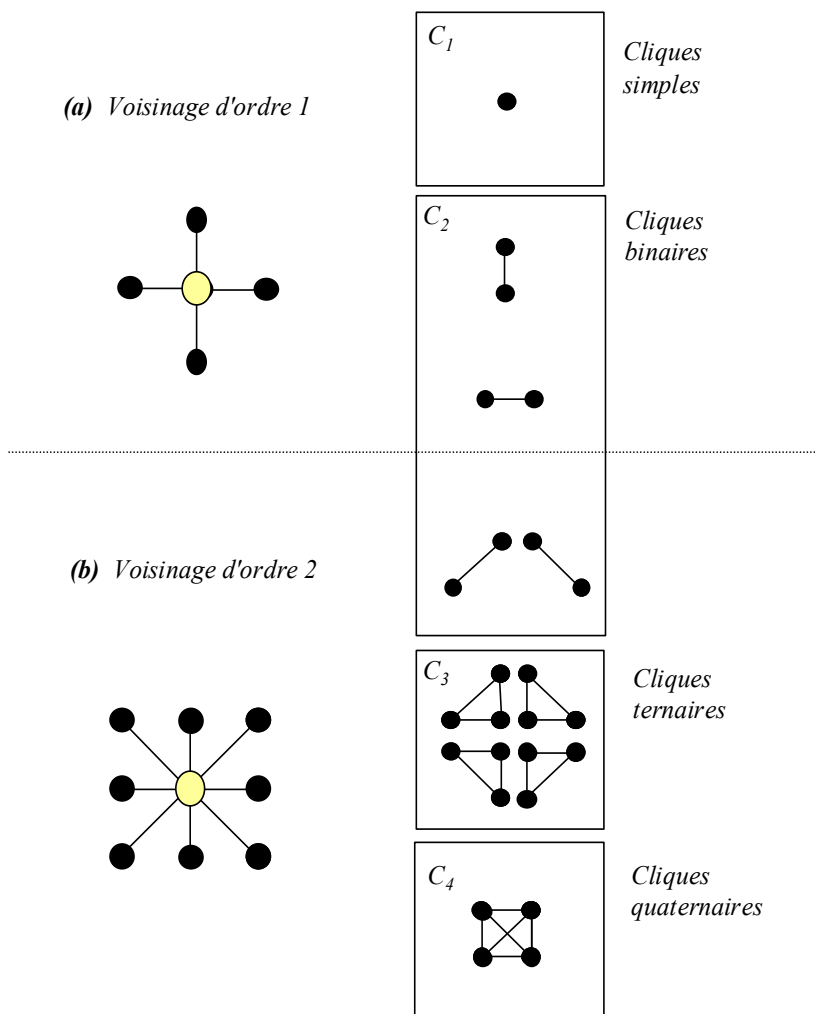


Fig.I.4 : Voisinages (a) d'ordre 1 et (b) d'ordre 2 et cliques correspondantes. Les sept dernières cliques sont exclusives du voisinage d'ordre 2.

3.2 Théorème d'équivalence

La définition du champ de Markov à partir des seules distributions marginales ne semble offrir aucune issue permettant d'aboutir à la distribution conjointe recherchée (ou terme d'*a priori*) $Pr(E)$. C'est pourquoi l'utilisation des champs de Markov en traitement d'images n'a été effective qu'à la découverte du théorème de Hammersley-Clifford qui établit l'équivalence entre champ de Markov et distribution de Gibbs :

Théorème de Hammersley-Clifford (ou théorème d'équivalence). Le théorème de Hammersley-Clifford [Besag72] stipule que E est un champ de Markov si et seulement si la distribution de probabilités globale du champ $\Pr[E=e]$ peut se mettre sous la forme *Gibbsienne* suivante :

$$\Pr[E = e] = \frac{1}{Z} \exp(-U_{reg}(e)) \quad (\text{Eq.I.d})$$

avec $Z = \sum_{e \in \Omega_E} \exp(-U_{reg}(e))$, et $U_{reg}(e) = \sum_{c \in C} V_c(e)$, où C désigne l'ensemble des cliques définie sur la grille¹² S et V_c est une fonction de potentiel associé à la clique¹³ $c \in C$.

Par la suite, la fonction U_{reg} sera indistinctement appelée *énergie spatiale*, *énergie a priori*, *énergie de régularisation* ou encore *de lissage spatial*. Elle ne dépend que des variables du champ à estimer et non du champ d'observation.

Un champ de Markov peut donc être défini en spécifiant les potentiels des cliques V_c ; les probabilités conditionnelles locales du champ s'écrivent alors :

$$\Pr[E(s) = e(s) / E(r) = e(r), \forall r \in S, r \neq s] = \frac{1}{Z_s} \exp[-U_s(e)],$$

$$\text{où } Z_s = \sum_{g \in G_E} \exp(-U_s(e) |_{e(s)=g}) \text{ et } U_s(e) = \sum_{c \in C: s \in c} V_c(e).$$

La définition des potentiels élémentaires sera spécifique au problème à résoudre ; la force de l'approche markovienne réside justement dans le fait qu'il est beaucoup plus aisé de décrire et interpréter les interactions par le biais d'un potentiel que par l'écriture des distributions conditionnelles locales. De plus, la *seule* contrainte à respecter est que chaque potentiel V_c ne dépende que des pixels de la clique correspondante.

Ainsi, le terme *a priori* $\Pr(E)$ que l'on cherchait pour compléter la règle de Bayes est tout simplement explicitée par la distribution de Gibbs de l'éq.I.d ci-dessus.

¹² Si l'on distingue la cardinalité des cliques, alors on peut poser :

$$U(e) = \sum_{c \in C_1} V_c(e) + \sum_{c \in C_2} V_c(e) + \sum_{c \in C_3} V_c(e) + \sum_{c \in C_4} V_c(e)$$

(dans le cas d'un champ de Markov défini sur un voisinage d'ordre 2).

¹³ Par définition, l'ensemble de cliques associés à un voisinage donné correspond à l'union des sites singletons et de tous les sous-ensembles du voisinage composés de sites voisins deux-à-deux (voir fig.I.4).

Exemple (suite) : si l'on s'intéresse toujours à la restitution d'images bruitées et si l'on modélise l'image par un MRF défini par rapport à un voisinage d'ordre 1, alors il est classique de modéliser la contrainte d'homogénéité spatiale de l'image par un potentiel portant sur les cliques binaires de la forme :

$$V_c(e) = V_c[e(s), e(r)] = \beta_s \cdot (e(s) - e(r))^2, \text{ avec } \beta_s > 0$$

où c est la clique binaire comprenant les sites voisins s et r . Les configurations localement favorisées sont celles pour lesquelles les sites ont le même niveau de gris [Murray87], [Derin87], [Lalan90b]. La forme quadratique du potentiel spatial ressemble dans ce cas à celle du potentiel de contrainte Ψ trouvé lors de la modélisation du processus d'observation (dans le cas de variables binaires, le potentiel ainsi défini devient un potentiel à deux niveaux $0, \beta_s$ - symétrisé en $\pm\beta_s$ par addition d'une constante). L'énergie spatiale (ou terme de régularisation, ou encore de lissage spatial) s'écrit finalement :

$$U_{reg}(e) = \sum_{c \in C_2} V_c(e) = \frac{\beta_s}{2} \sum_{s \in S} \sum_{r \in V(s)} (e(s) - e(r))^2$$

La valeur du paramètre β_s dépend des caractéristiques spatiales de l'image réelle non bruitée¹⁴. Par exemple, le paramètre sera plutôt faible pour une image ayant une forte granularité ou des textures fines, et plutôt fort pour une image homogène. En fait β_s peut être estimé pour une image et un système de voisinage données, à condition de définir un critère d'erreur (de reconstruction) [Marro85a]. On peut également estimer la valeur de β_s sur un échantillon d'images "réelles" (voir remarque au §5.1).

3.3 Le problème de l'estimation des paramètres.

La formulation correcte d'un problème particulier en termes de fonction d'énergie à minimiser passe par le choix d'un certain nombre de paramètres définissant aussi bien les potentiels des cliques spatiales que le modèle d'observation. Dans la majorité des cas, ces paramètres sont fixés empiriquement ; ils peuvent être déterminés une fois pour toutes ou être réactualisés périodiquement en fonction des nouvelles images acquises.

Certains auteurs proposent encore des techniques *d'estimation* des paramètres du modèle. Azencott [Azenco88] propose par exemple une méthode de calibration consistant à fixer conjointement des configurations locales particulières du champ d'étiquettes *et* du champ d'observation, et d'imposer ensuite à chacune d'entre elle une probabilité conditionnelle locale. Ces probabilités sont proches de 0 ou 1 car les configurations sont volontairement exemplaires et donc extrêmes. Il en résulte un ensemble d'équations liant les paramètres du modèles. Une illustration de cette méthode est développée dans [Letang93] ; nous avons testé la méthode dans un cas très simple (débruitage d'images binaires, cf.§5.1). Une autre technique consiste à estimer les paramètres conjointement à l'estimation bayésienne [Besag86], [Derin89].

¹⁴ En toute généralité, c'est le choix du *système de voisinage du champ* tout entier (topologie, forme et valeurs des potentiels) qui en dépend ; on ne s'intéresse ici qu'à un voisinage d'ordre 1 ou 2 invariant par translation, et pour lequel le potentiel des cliques peut prendre uniquement deux valeurs $\pm\beta_s$.

4. Estimateur MAP et minimisation de l'énergie

4.1 Construction de la fonction de coût.

En remplaçant dans la formule de Bayes (éq.I.a) le terme de vraisemblance par son expression dans l'éq.I.c et le terme a priori par la formule de l'éq.I.d, on obtient finalement l'expression de la probabilité a posteriori :

$$\Pr(E = e / O = o) = \frac{1}{\Pr(O = o)} \cdot \frac{1}{Z} \cdot \exp\left[-\left(U_{obs}(e, o) + U_{reg}(e)\right)\right]$$

L'introduction de la modélisation markovienne dans le cadre de l'estimation bayésienne permet, comme annoncé, d'avoir recours à des distributions gibbsiennes. Le critère du MAP, c'est à dire la maximisation de la probabilité a posteriori par rapport au champ des labels e étant donné un champ d'observations o , est alors équivalent à la minimisation d'une fonction de *coût* ou *énergie* totale comprenant deux termes :

$$U(e, o) = U_{obs}(e, o) + U_{reg}(e)$$

- Le premier terme est un terme de *rappel* aux données qui provient du modèle du processus d'observation ;
- Le deuxième terme est un terme de *régularisation* qui intègre les connaissances *a priori* dans le modèle (champ de Markov).

La fonction d'énergie est une fonction à grand nombre de variables (i.e. le champ d'étiquettes). La nature des interactions et du processus d'observation peut conduire à des fonctions qui ne sont *ni quadratiques ni convexes* par rapport aux variables ; l'énergie peut comporter alors plusieurs minimums locaux. Par contre, dans le cas d'une fonction quadratique et convexe, on est assuré de l'existence d'un minimum global. Ce minimum peut être obtenu par des méthodes d'optimisation déterministes classiques de type *descente de gradient* (plus forte pente à pas optimal, gradients conjugués, méthode de Newton).

Remarque : La distribution de probabilités *conjointe* du champ d'étiquettes et du champ d'observation $\Pr[E=e, O=o]$ s'écrit :

$$\Pr(E = e, O = o) = \frac{1}{Z} \cdot \exp[-U(e, o)].$$

Or, la fonction d'énergie globale $U(e, o)$ peut s'écrire comme somme de potentiels de cliques "généralisées" $c \in C_X$ reliant le champ d'étiquettes et le champ d'observation :

$$U(e, o) = \sum_{c \in C_x} V_c(e, o) = \sum_{s \in S} V_s(e, o) + \sum_{c \in C} V_c(e),$$

où $V_s(e, o) = \Psi_s(e, o(s))$ (voir §2.3). Autrement dit, et en vertu du théorème de Hammersley-Clifford, le champ *couplé* $X = \{E, O\}$ est un champ de Markov.

Exemple (suite) : Si l'on remplace dans la formule de Bayes le terme de vraisemblance et le terme d'a priori par les expressions correspondant au problème de la restauration d'images, alors l'énergie à minimiser prend la forme finale :

$$U(e, o) = \frac{1}{2\sigma^2} \sum_{s \in S} (e(s) - o(s))^2 + \frac{\beta}{2} \sum_{s \in S} \sum_{k \in V(s)} (e(s) - e(k))^2,$$

que l'on a coutume d'exprimer de la façon suivante :

$$U(e, o) = \sum_{s \in S} (e(s) - o(s))^2 + \lambda \sum_{s \in S} \sum_{k \in V(s)} (e(s) - e(k))^2$$

Le facteur λ permet de pondérer le terme de rappel aux données par rapport au terme de régularisation [Blake87]. Remarquons enfin que U est quadratique *et* convexe par rapport aux variables du champ (dans le cas de niveaux de gris continus) : on est alors assurés qu'il existe un minimum global de l'énergie. Qui plus est, celui-ci peut être trouvé en un temps polynomial par des algorithmes *variationnels* déterministes de type descente de gradient.

4.2 Remarque : estimateurs MPM et MF.

L'estimation au sens du MPM ou du MF n'est pas immédiate¹⁵ : pour le premier, il manque les distributions marginales *a posteriori*, qui ne sont pas directement accessibles en général. La difficulté du MF provient aussi du fait que son calcul passe par la connaissance de la fonction de partition de la distribution *a posteriori*. Cependant, en raison du caractère moins brutal de la fonction de coût employée¹⁶, l'estimateur MPM semble se comporter mieux que le MAP lorsque le processus de formation des observations introduit un bruit important [Prémon99]. Par ailleurs, les deux estimateurs pourraient être implantés facilement dans notre démonstrateur optoélectronique (*cf.* Chap.III). En effet, et comme on le verra au chapitre suivant, le noyau de l'algorithme d'optimisation stochastique utilisé pour résoudre la minimisation de la fonction d'énergie (dans le cadre de l'estimateur MAP) nécessite la mise en place d'*échantillonneurs* Gibbsiens ; une stratégie pour obtenir les estimés du MPM ou du MF peut consister alors à *estimer* les propriétés statistiques *a posteriori* de l'image à partir d'un large échantillon d'images (loi des grands nombres) issu d'une procédure d'échantillonnage (*cf.* Chap.II, §2.2.2). Ainsi, l'estimé du MF est tout simplement approché par la moyenne de tous les échantillons, et l'estimé du MPM (en chaque site) est approché par l'étiquette

¹⁵ ...pour le moins en ce qui concerne la *formulation* du problème d'optimisation : en général, le calcul de l'estimateur MAP n'est *pas* immédiat non plus (voir chapitre suivant).

¹⁶ La fonction de coût associé à l'estimateur MAP pénalise de la même façon toutes les configurations non optimales, alors que la fonction de coût du MPM pénalise chaque configuration *par rapport au nombre de pixels différents de la configuration optimale*.

apparaissant le plus fréquemment dans les échantillons. Nous n'avons pas exploré ces possibilités ; seul l'estimateur du MAP a retenu toute notre attention, la raison principale étant la formulation mathématique rigoureuse du problème comme un problème *d'optimisation*.

5. Quelques exemples

Nous allons introduire par la suite quelques problèmes en traitement d'images pour lesquels la fonction d'énergie n'est *ni quadratique ni convexe*. C'est uniquement à ce type de problèmes *difficiles* que nous allons nous intéresser dans le chapitre suivant.

Les problèmes présentés ici feront l'objet de quelques démonstrations sur le prototype optoélectronique (Chap.VI), c'est pourquoi il s'agit plutôt de cas d'école. Nous n'avons pas abordé ici des traitements de type spatio-temporels qui pourraient bénéficier de l'approche bayésienne et de la régularisation markovienne ; cela sera l'objet du Chap.IV - pour le cas particulier de la détection du mouvement- et donnera également lieu à une démonstration sur le prototype optoélectronique (Chap.V et VI).

5.1 Débruitage d'images binaires et modèle d'Ising.

5.1.1 Définition de la fonction de coût ou énergie.

Nous avons déjà présenté le problème de la restauration d'images à niveaux de gris. Intéressons nous maintenant au cas de la restauration d'images *binaires*. Supposons par ailleurs que le champ observé est lui-même binaire. Alors, la modélisation la plus simple du processus d'observation fait intervenir non pas un bruit gaussien, mais un *bruit de canal* de taux d'erreur ε , défini selon :

$$\Pr[O(s)=1 / E(s)=0] = \Pr[O(s)=0 / E(s)=1] = \frac{\varepsilon}{2}, \text{ et}$$

$$\Pr[O(s)=0 / E(s)=0] = \Pr[O(s)=1 / E(s)=1] = \frac{1-\varepsilon}{2}.$$

En notant $\beta_o = \ln\left(\frac{1-\varepsilon}{\varepsilon}\right)$, on peut exprimer le terme de vraisemblance marginal par :

$$\Pr[O(s)=o(s) / E(s)=e(s)] = \frac{\varepsilon}{2} \exp[\beta_o \cdot \delta(o(s)-e(s))],$$

avec $\delta(0)=1$ et 0 sinon. La *vraisemblance* de l'observation $O=o$ est alors :

$$\Pr(O = o / E = e) = \left(\frac{\varepsilon}{2}\right)^{n \times m} \exp\left(\beta_o \sum_{s \in S} \delta(o(s)-e(s))\right)$$

L'énergie de rappel à l'observation est enfin (à une constante additive près, ce qui ne change pas la solution finale résultat de la recherche du *minimum* énergétique) :

$$U_{obs}(e, o) = -\beta_o \sum_{s \in S} \delta(o(s) - e(s)), \text{ soit finalement :}$$

$$U_{obs}(e, o) = -\frac{\beta_o}{2} \sum_{s \in S} (2o(s) - 1) \cdot (2e(s) - 1).$$

Par ailleurs, si l'on choisit un potentiel de régularisation spatial à deux niveaux $\pm\beta_s$:

$$\forall (r, s) \in S \times S, V_c(e(s), e(r)) = -\beta_s \cdot (2e(s) - 1) \cdot (2e(r) - 1),$$

alors l'énergie de régularisation spatiale s'écrit : $U_{reg}(e) = -\frac{\beta_s}{2} \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1) \cdot (2e(r) - 1)$

L'énergie *totale* à minimiser pour la restauration d'images binaires bruitées est finalement :

$$U(e, o) = -\beta_s \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1) \cdot (2e(r) - 1) - \beta_o \sum_{s \in S} (2o(s) - 1) \cdot (2e(s) - 1) \quad (\text{Eq.I.e})$$

On reconnaît dans le premier terme de la formule le *Hamiltonien* d'un système de spins en interaction mutuelle ou *modèle d'Ising bidimensionnel* [Landau67]. Dans ce cas précis les interactions sont toutes *positives* (le coefficient de couplage vaut $J_{rs} = \beta_s$) ce qui correspond au cas des matériaux *ferromagnétiques*. La configuration d'énergie minimale pour le modèle *ferromagnétique* ou *anti-ferromagnétique* est connue d'avance : il s'agit d'un champ d'étiquettes uniforme (+1 ou 0) pour le cas ferromagnétique et d'un champ en damier (direct et inverse) dans le cas anti-ferromagnétique. Ceci est possible car il n'y a pas de phénomène de "frustration" (autrement dit, les configurations d'énergie minimale *locale* sont compatibles avec la configuration d'énergie minimale *globale*). Le phénomène de frustration apparaît par exemple quand toutes les coefficients de couplage n'ont pas le même signe (*Verre de Spin*), ou quand on couple le système ferromagnétique avec un champ magnétique externe *non uniforme*. L'image à restaurer $O=o$ joue ici le rôle de ce champ magnétique externe non uniforme (deuxième terme de la formule). Expliciter alors la configuration du minimum énergétique est un tout autre problème - très difficile.

5.1.2 Choix des paramètres β_s et β_o .

Si l'on définit la "granularité" (d'ordre 1) d'une image comme étant le rapport du nombre de paires de pixels voisins ayant la même étiquette au nombre total de pixels de l'image, alors on constate que pour des images générées selon la loi *d'a priori* du modèle, la granularité décroît avec β_s en suivant une courbe qui rappelle celle de la magnétisation d'un matériau ferromagnétique en fonction de la température. En particulier il existe une valeur critique qui fait chuter brutalement la granularité de l'image en faisant apparaître de domaines uniformes. Ce n'est pas par hasard : la température critique correspondant à

une *transition de phase* pour l'Ising ferromagnétique bidimensionnel (défini par l'Hamiltonien du premier terme de l'éq.I.e) vaut à peu près $T_{cm} = v \cdot \beta_S$ en utilisant l'approximation du *champ moyen* (ce qui implique en principe que le cardinal du voisinage soit $v \gg 1$) ; dans le cas d'un voisinage 4, cette température peut être calculé exactement [Diu] : elle vaut $T_c = 0,567 \cdot T_{cm} \approx 2,27 \cdot \beta_S$. Or, la loi d'*a priori* du modèle de Markov $\Pr(E)$ correspond à la distribution de Gibbs du modèle d'Ising pour $\beta_S' = \beta_S/T$. Il n'est donc pas étonnant que la granularité chute quand $\beta_S' = \beta_S/T_c = 1/2,27 = 0,44$. Prendre β_S en *dessus* de cette valeur signifie que les images à modéliser présentent principalement des régions homogènes ; inversement, choisir un paramètre β_S en dessous de cette valeur signifie que les images à traiter présentent naturellement une granularité élevée. On prendra dans nos exemples (voir fig.I.4) β_S supérieur à 0,44.

A un facteur multiplicatif près (ce qui n'a pas de conséquence sur le *résultat* de l'optimisation), la fonction de coût ne dépend en réalité que d'un seul paramètre, le *rapport* $\lambda = \beta_S/\beta_o$:

$$U(e, o) = - \sum_{s \in S} (2o(s) - 1)(2e(s) - 1) - \lambda \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1)(2e(r) - 1).$$

Le facteur λ traduit la *confiance* (ou plutôt la *méfiance*) que l'on peut faire au champ de données issu de l'observation : si le bruit de canal est nul -l'observation correspond exactement à l'image originelle-, alors le facteur λ est lui aussi *nul* ($\beta_o \rightarrow +\infty$) et il n'y aura pas d'effet de régularisation : le minimum de l'énergie correspond tout simplement à l'image observée. Si par contre le bruit atteint 50% (le champ d'observation ne contient alors aucune information pertinente, $\beta_o \rightarrow 0$), le terme de contrainte est négligeable, traduisant le fait que seule la connaissance *a priori* que l'on a sur les images est à prendre en considération (le résultat de l'optimisation correspond à une image entièrement uniforme).

Remarque : Si l'on choisit d'utiliser l'estimateur MPM, alors le résultat de l'optimisation en présence d'un bruit important correspond à une image aléatoire de granularité correspondant à celle de l'image que l'on aurait voulu reconstruire (à condition que le paramètre β_S ait été bien estimé au préalable). C'est pourquoi à notre avis l'estimateur du MPM semble se comporter mieux en présence d'un bruit important.

Enfin, le facteur λ peut être estimé de façon plus ou moins heuristique (cf.§3.3). Nous avons testé deux façons de le faire :

1. En imposant des contraintes sur le résultat de l'optimisation (c'est une version simplifiée de la technique d'Azencott [Azenco88]) L'idée consiste à rendre improbables certaines configurations locales ; ainsi pour un voisinage d'ordre 2, on voudra éviter qu'un pixel "s'aligne" avec la donnée de l'observation locale, si plus de

4 pixels du voisinage lui "indiquent" le contraire. Ceci se traduit exactement par l'inéquation (à condition d'utiliser l'estimateur du MPM)¹⁷ :

$$(+5.\beta_S - 3.\beta_S) > \beta_o, \text{ c.à.d. : } \lambda > 1/2.$$

2. Plus simplement on a tenté d'ajuster "à l'œil" le paramètre λ pour un type spécifique d'images donnée. Ceci nous a conduit, pour les images binaires très simples qui serviront à tester le démonstrateur optoélectronique (i.e. lettres de l'alphabet latin bruitées), à des valeurs de λ comprises entre 0.4 et 0.6 pour un voisinage 8 et entre 0,9 et 1,2 pour un voisinage 4 (voir *fig.I.4*).

¹⁷ Nous allons utiliser par la suite *l'estimateur du MAP*. La condition tient aussi dans ce cas, mais avec une signification légèrement différente : elle implique que *pendant* toute la durée du recuit (i.e. à toute température, cf Chap.II), la configuration aléatoire tirée respecte localement ces contraintes ; cependant, puisque la configuration finale minimise l'énergie *globale*, la contrainte locale sera certainement violée beaucoup plus souvent dans celle-ci.

Images binaires bruitées (40x40)



Bruit de canal : 5% 15% 25% 35% 45%

Filtrage passe-bas



Optimisation déterministe (ICM)



Optimisation Stochastique (SA)

Restauration ($v=8$)



Filtrage passe-bas



Optimisation déterministe (ICM)



Optimisation Stochastique (SA)

Restauration ($v=4$)



Fig.I.4 : Exemple de restauration d'images binaires bruitées. (Pour détails sur les méthodes d'optimisation, voir commentaires au Chap.II).

5.1.3 Restauration d'images avec prise en compte des bords.

Dans le cas de la restauration d'images à niveaux de gris continus (cas beaucoup plus intéressant en traitement d'images), la fonction d'énergie est quadratique par rapport aux variables du champ. Le minimum de la fonction d'énergie peut donc être obtenu par une méthode de type *descente de gradient*. On remarquera cependant que le modèle de débruitage proposé ne tient pas compte des discontinuités propres de l'image (le bruit est tenu pour responsable de tous les sauts brutaux entre niveau de gris). Ce n'est pas là simplement une remarque, c'est également un important défaut du modèle. Il est cependant facile de modifier le modèle pour tenir compte des bords à l'intérieur de l'image et en faire un modèle de restauration beaucoup plus réaliste. En effet, une technique maintenant classique ([Geman84], [Blake87]) consiste à introduire des informations *a priori* sur les discontinuités de l'image par l'adjonction d'un deuxième champ de Markov (binaire cette fois-ci) appelé *processus de ligne* et noté L .

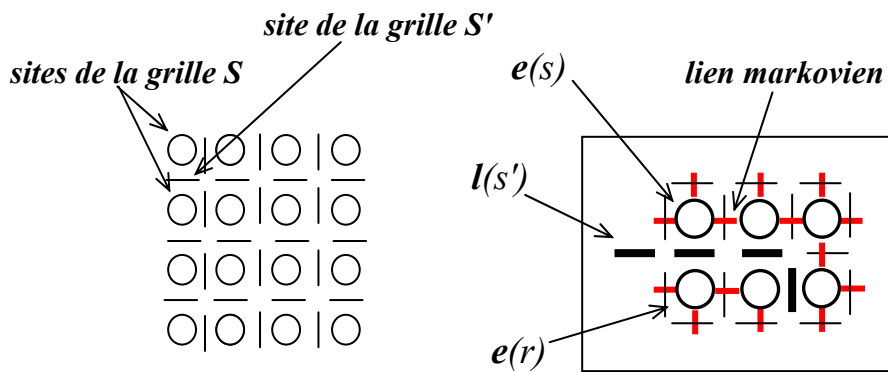


Fig.I.6 : Champ de Markov couplé pour la restauration avec prise en compte des discontinuités.

Les sites s' de la grille S' , support du champ L , s'intercalent entre les sites s du champ E . Le bord $l(s') \in \{0,1\}$ agit comme un *interrupteur* coupant le "lien markovien" entre deux sites voisins du champ E (voir fig.I.6). Ce *champ de discontinuités ou bords*, forme avec le champ E de niveaux de gris un champ de Markov couplé (E,L) qui modélise l'ensemble des connaissances *a priori* sur l'image (niveaux de gris et bords). La fonction d'énergie à minimiser prend la forme suivante :

$$U(e,o,l) = \sum_{s \in S} (e(s) - o(s))^2 + \lambda \left\{ \sum_{s \in S} \sum_{r \in V(s)} (e(s) - e(r))^2 \cdot (1 - l_{sr}) + \Psi_B(l) \right\},$$

(dans l'expression ci-dessus, l_{sr} représente le bord du site s' entre le site s et r). De la même façon que le champ E permet de prendre en compte les propriétés spatiales "agglutinantes" des niveaux de gris, le processus de ligne L peut prendre en compte les caractéristiques markoviennes spatiales des bords (par exemple, la probabilité d'avoir un bord entièrement entouré de bords est plutôt faible, la probabilité d'avoir un bord isolé

aussi, etc.). Ces propriétés ne sont pas modélisables par des potentiels simples comme pour le champ de niveaux de gris, et en général on se réfère à des tables ajustées de façon heuristique (fonction $\Psi_B(l)$ dans l'expression ci-dessus). La recherche du minimum de la fonction d'énergie devient alors un problème *difficile*, dont la résolution n'est possible qu'en ayant recours à des algorithmes stochastiques sous-optimaux (cf. Chap.II). Prévost [Prévost95] étudie les principes et la faisabilité d'une rétine artificielle VLSI pouvant traiter le problème de la restauration d'images à niveaux de gris continus avec prise en compte des discontinuités (voir travaux précurseurs de Poggio et Koch [Poggio85]).

5.2 Codage en demi-teintes.

Le *codage en demi-teintes* ou *procédé de tramage* d'une image à niveaux de gris - *halftoning* en anglais- consiste à créer à partir de celle-ci une image binaire qui soit perçue par l'œil comme l'équivalent de l'image originale (fig.I.7). L'opération s'avère très utile dans le domaine de l'imprimerie (journaux, affiches et imprimantes de bureau), car il est plus facile de mettre au point des mécanismes d'impression en *tout ou rien* (imprimantes jet d'encre, à aiguilles, etc), non concernés en outre par des problèmes de réglage délicats du rendu des niveaux de gris. A notre connaissance, le procédé de codage en demi-teintes qui semble donner les meilleurs résultats est un problème d'optimisation difficile (voir plus bas), c'est pourquoi dans la pratique on utilise des variantes déterministes sous-optimales.



Fig.I.7 : A gauche, une image 476x476 pixels à 256 niveaux de gris (227Ko). A droite, image binarisée par la méthode de diffusion d'erreur (seulement 28 Ko car on n'a pas modifié la résolution). Même pour une résolution à l'impression qui reste assez faible (200ppi), la résolution tonale de l'image est acceptable.

Une argumentation du même genre peut être soutenue quant au problème de l'affichage dynamique : il est plus facile de réaliser des éléments optiques de commutation en tout ou rien que des pixels capables de reproduire avec précision une échelle d'intensité donnée (les matériaux électro-optiques sont par essence non-linéaires). De plus, par rapport à l'impression sur papier, la qualité de l'image sur écran se voit détériorée par la dispersion des caractéristiques entre pixels d'une même matrice.

Il est vraisemblable que des écrans binaires larges et/ou de haute résolution (ce qui améliore la qualité du rendu en demi-teintes) soient plus faciles à mettre au point que leurs homologues à niveaux de gris ; l'affichage d'images binarisées pourrait donc être une solution intéressante pour les applications ne nécessitant pas une restitution *exacte* de l'information binaire de l'image, mais seulement des qualités perceptibles à l'œil (tout écran d'affichage : affiches publicitaires, écrans d'ordinateur, et aussi télévision!, etc.). En résumé, le codage en demi-teintes en temps réel par recuit simulé pourrait (1) améliorer la *qualité* du rendu en demi-teintes des images larges dans le domaine de l'imprimerie (en particulier les affiches publicitaires) et (2) permettre l'utilisation d'écrans *binaires* de grande résolution et/ou taille pour l'affichage d'images à niveaux continus (le codage en demi-teintes en temps réel pourrait être à l'ordre du jour si le support multimédia à base *d'encre électronique* se généralise -système *gyricon* de Xerox [Gyricon] et l'*E-ink* de [MediaL99]).

Un autre avantage du codage en demi-teintes d'images est la possibilité de rendre celle-ci compatible avec un traitement numérique de type BIA (pour *Binary Image Algebra* [Huang89]) réalisable en technologie numérique sur des rétines artificielles VLSI (par exemple grâce à des opérateurs booléens invariants par translation [Zavido81], [Bernar92]). En toute généralité, le codage en demi-teintes est un cas particulier de *B-code* de l'image, représentation binaire pertinente de l'image relativement au système de conversion analogique-numérique donné (il est clair qu'un simple seuillage est un B-codage beaucoup plus pauvre). Ainsi, si l'on dispose à la fois d'un B-codeur efficace (rapide et de bonne qualité) et de dispositifs d'affichage binaires de grande résolution, la transmission (et le traitement) des images pourrait se faire sans avoir recours à un codage en niveaux de gris ; encore faudrait-il savoir si la bande passante nécessaire pour la transmission et le stockage d'images B-codées est plus grande ou plus petite que leur équivalent en niveaux de gris (bien évidemment l'image B-codée occupe moins d'espace mémoire si la résolution d'origine est conservée -voir *fig.I.7-* ; cependant en augmentant la résolution on améliore beaucoup la qualité visuelle du rendu tonal, mais la taille mémoire augmente...).

Venons enfin à la modélisation mathématique du problème. Le problème du codage en demi-teintes (ou B-codage *neuronal* [Bernar92]) peut être modélisé grâce à la fonction d'énergie à minimiser [Prémon99]:

$$U(e, o) = \sum_{s \in S} \left\{ [K^{-1} * o](s) - [K * e](s) \right\}^2 ,$$

où o est l'image à niveaux de gris, e est le champ d'étiquettes binaire à estimer (l'image B-codée), K^{-1} et K sont les noyaux de convolution permettant de réaliser respectivement le *rehaussement des bords* de l'image originale et le *flou* sur l'image binaire résultat (simulation de la réponse impulsionnelle de l'œil). L'énergie à minimiser est tout simplement la différence quadratique entre l'image binaire et l'image originale *telle*

qu'elles sont perçues par l'œil, le rehaussement des bords permettant d'éviter une perte de résolution spatiale. Il s'agit bien entendu d'un problème d'optimisation *difficile*.

6. Conclusion

Dans ce premier chapitre nous avons présenté une approche probabiliste générale permettant de **régulariser** les problèmes **mal posés** rencontrés en vision bas-niveau. Ceci est possible grâce à l'utilisation **d'estimateurs bayesiens**, dont par exemple l'estimateur du **maximum a posteriori** (MAP). Nous avons eu l'occasion de voir comment l'utilisation conjointe d'un **modèle de Markov** (MRF) chargé de représenter le champ de primitives, et d'une modèle probabiliste approprié du **processus d'observation**, permettait d'explicitier les termes de la formule de Bayes. Nous avons montré ensuite que l'estimation au sens du MAP est équivalente à la recherche de l'argument **minimisant une fonction de coût ou énergie** spécifique au problème, fonction que l'on a pu exprimer comme étant la somme de deux termes exerçant des influences "complémentaires" sur le résultat de l'optimisation (terme de contrainte aux données et terme de lissage spatial). Enfin, nous avons expliqué que la minimisation de la fonction d'énergie est, sauf dans quelques cas très particuliers, un problème d'optimisation **difficile** au sens algorithmique ; qui plus est, les seuls algorithmes (déterministes) que l'on puisse concevoir sont, comme on le verra au chapitre suivant, irrémédiablement sous-optimaux (le minimum global de l'énergie ne peut être trouvé que si l'on part d'une configuration déjà très proche de la solution).

L'objet du chapitre suivant sera donc de présenter la technique dite du *recuit simulé*, méthode d'optimisation *stochastique* permettant en principe de venir à bout de n'importe quel problème d'optimisation difficile - à condition toutefois d'avoir suffisamment de temps disponible.

Chapitre II

Recuit Simulé Parallèle

1. Introduction

Nous avons vu au chapitre précédent comment l'estimation bayésienne associée à une modélisation markovienne du champ des primitives permet d'exprimer formellement un certain nombre de problèmes en analyse d'images bas niveau comme un problème d'optimisation, consistant à *minimiser une fonction d'énergie ou coût*. Cette énergie intègre un terme de *régularisation* qui exprime les connaissances *a priori* que l'on a sur la solution - telle que l'homogénéité spatiale de l'image - et un terme de *rappel aux données* qui résulte de la modélisation probabiliste du processus d'observation.

La formulation d'un grand nombre de problèmes en traitement d'images bas niveau gagne ainsi en rigueur mathématique, mais on n'est pas pour autant beaucoup plus près de leur résolution pratique. En effet, le calcul du minimum de la fonction d'énergie ne peut pas être réalisé par une recherche exhaustive sur l'ensemble de solutions possibles : le cardinal de cet ensemble est immensément grand (égal à $\Omega=L^{nm}$, avec en général L, n et m de l'ordre de 256). Par ailleurs, la fonction d'énergie n'est en général ni quadratique ni convexe par rapport aux variables du problème et la recherche du minimum global est loin d'être un problème trivial d'un point de vue analytique. Ceci est vrai aussi des fonctions dont les variables prennent des valeurs *discrètes* (niveaux de gris discrets) : dans ce cas, même des fonctions qui seraient quadratiques et convexes pour des variables continues présentent non pas un seul minimum global, mais un nombre considérable de minima locaux : on dit que le paysage énergétique est accidenté ou *sauvage*.

La minimisation de ce genre de fonctions est en fait un problème d'optimisation combinatoire *difficile*, dont le problème du "voyageur de commerce" représente l'exemple le plus connu. Les algorithmes *stochastiques* apportent une réponse à ces ardues problèmes d'optimisation.

1.1 Quelques exemples de problèmes d'optimisation.

Avant d'aller plus en avant, on a voulu donner au *tab.II.1* un aperçu des quelques domaines et/ou problèmes dont la résolution implique la minimisation d'une fonction d'énergie à grand nombre de variables en interaction. On a gardé les notations du chapitre précédent pour le champ d'étiquettes E (variables) ainsi que pour le champ d'observation O (donnés) dans le but de mieux saisir l'analogie existante entre le modèle probabiliste bayésien dédié à l'extraction de primitives bas-niveau des images et la résolution de problèmes qui peuvent sembler a priori étrangers au domaine du traitement des images. Par exemple, d'un point de vue *connexioniste*, la restauration d'une image binaire bruitée peut être interprétée comme le résultat de l'*association* de l'image dégradée (état initial du réseau de neurones) à l'*attracteur* le plus proche du réseau - attracteur qui est localement lissé par construction. L'interprétation physique s'avère également très instructive (*cf.* Chap.I,§5.1). Dans ce cas, l'image binaire bruitée représente un champ magnétique externe non uniforme appliqué sur un réseau bidimensionnel de spins (+1 ou -1) en interaction *ferromagnétique* (modèle d'Ising 2D ferromagnétique). En dessous d'une certaine *température critique*, des domaines ferromagnétiques (zones homogènes de magnétisation) apparaissent sur le réseau, dont l'orientation correspond plus ou moins directement à celle imposée localement par le champ externe ; grâce aux interactions entre les spins, le "bruit" du champ n'est pas entièrement recopié par le système et l'image (codée par l'ensemble des spins) se trouve ainsi *régularisée*.

Tab.II.1 : Ci-dessous, quelques problèmes modélisables par des fonctions d'énergie à grand nombre de variables en interaction :

Champ d'étiquettes binaire	
<p>Physique Statistique. (étude des transitions de phase)</p>	<p>Modèle d'Ising 2D pour le verre de spin. Le champ d'étiquettes binaire représente l'état du réseau bidimensionnel de spins en interaction, couplé avec un champ magnétique extérieur h ; les constantes de couplage J_{rs} sont bipolaires (± 1) :</p> $U(e,o) = -\sum_{s \in S} \sum_{r \in V(s)} J_{sr} (2e(s)-1)(2e(r)-1) + h \cdot \sum_{s \in S} (2e(s)-1).$ <p>La résolution analytique du problème (température critique, aimantation) n'est connue que pour des cas très particuliers [Landau67].</p>
<p>Traitement du signal. (approche connexionniste par réseaux de neurones pour la reconnaissance de formes, la mise en forme des signaux, etc...)</p>	<p>Une fois que l'apprentissage du <u>réseau de Hopfield</u> [Hopfie82] est réalisé, l'association entre une observation et un <u>vecteur d'apprentissage</u> se fait par minimisation <u>déterministe</u> de la fonction de coût :</p> $U(e) = -\frac{1}{2} \sum_{(s,r) \in S \times S} w_{s,r} \cdot e(s) \cdot e(r)$ <p>(le champ de labels -i.e. l'état du réseau- est initialisé grâce au champ d'observation o).</p> <p>La <u>machine de Boltzmann</u> [Hinton84] évite les minimum locaux indésirables (pièges) du réseau de Hopfield en introduisant des couches de neurones "cachées" et en améliorant la phase d'apprentissage et d'association par des méthodes d'optimisation <u>stochastique</u> ; la recherche du minimum énergétique est également réalisée de façon stochastique.</p>
<p>Traitement d'images bas-niveau (extraction de primitives bas-niveau, segmentation de textures, extraction de contours, etc.)</p>	
Champ d'étiquettes continu	Champ d'étiquettes binaire
<p><u>Restauration</u> d'images à niveau de gris continu, sans prise en compte des discontinuités :</p> $U(e,o) = \sum_{s \in S} (e(s) - o(s))^2 + \lambda \sum_{s \in S} \sum_{r \in V(s)} (e(s) - e(r))^2$ <p>L'énergie est <u>quadratique et convexe</u> ; la solution optimale est l'équivalent d'un <u>filtrage passe-bas</u> de l'image originale.</p>	<p><u>Restauration</u> d'images <u>binaires</u> bruitées (cf. Chap.I, §5.1).</p> $U(e,o) = -\beta_o \sum_{s \in S} (2o(s)-1)(2e(s)-1) + \beta_s \sum_{s \in S} \sum_{r \in V(s)} (2e(s)-1)(2e(r)-1)$ <p>Il s'agit d'un cas d'école, mais formellement équivalent au cas où les niveaux de gris sont <u>discrets</u> (il suffit de les coder en base 2 pour avoir une fonction d'énergie à variables binaires).</p>

<p><u>Restauration</u> d'un champ continu avec prise en compte des discontinuités (processus de bords L binaire) :</p> $U(e, o, l) = \sum_{s \in S} (e(s) - o(s))^2 + \lambda \sum_{s \in S} \sum_{k \in V(s)} (e(s) - e(k))^2 \cdot (1 - l_{sk}) + \lambda V(l)$ <p>(algorithme RQS [Prévos94])</p>	<p><u>Restauration</u> d'un champ multivalué (discret) avec prise en compte des discontinuités (processus de bords binaire) ; fonction d'énergie ci-contre [Geman90].</p> <p>Divers algorithmes ont été étudiés dans la littérature : Global, Mixed Annealing, [Marro85a], GNC [Blake87], etc.).</p>
<p>---</p>	<p><u>B-codeurs d'images</u>. Exemple : rendu en demi-teintes avec rehaussement des bords (cf. Chap. I§5.3) :</p> $U(e, o) = \sum_{i \in S} [(K^{-1} * O)_i - (K * E)_i]^2$ <p>Le champ d'observation est l'image à niveaux de gris, le champ d'étiquettes binaire représente l'image B-codée.</p>
<p>Traitement spatio-temporels (primitives spatio-temporelles : détection du mouvement, segmentation du mouvement, etc..)</p>	
<p><u>Estimation du mouvement</u> (optical flow) [Konrad88] :</p> $U(\vec{e}, o) = \sum_{s \in S} (o(s, t - dt) - o(s + \vec{e}(s).dt, t))^2 + \lambda \sum_{s \in S} \sum_{r \in V(s)} \ \vec{e}(s) - \vec{e}(r)\ ^2$ <p>Le champ d'étiquettes est <i>vectorel</i> et correspond à la vitesse estimée d'un point de l'image ; l'observation correspond au champ de niveaux de gris de la séquence d'images. L'énergie n'est pas quadratique par rapport aux variables.</p>	<p><u>Détection du mouvement</u> : modèle simplifié discret (cf. Chap. IV) :</p> $U(e, o) = -\beta_c \sum_{s \in S} (2o(s) - 1)(2e(s) - 1) - \frac{\beta_s}{2} \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1)(2e(r) - 1)$ <p>Le champ d'étiquettes binaire est un masque représentant les zones en mouvement. Le champ d'observation est aussi binaire et rend compte des changements temporels entre deux images consécutives de la séquence (<i>carte de changements temporels</i>).</p>

1.2 Les algorithmes d'optimisation : généralités.

Nous allons présenter par la suite les fondements théoriques des procédures de *relaxation stochastique*. Le but final est de bien saisir les raisons qui nous ont conduit à adopter l'algorithme stochastique dit de *recuit simulé* (*Simulated Annealing*) pour notre processeur optoélectronique, plutôt qu'un autre algorithme, de type déterministe par exemple ; il en existe en effet deux sortes d'algorithmes :

- ◆ Les algorithmes déterministes. Ils sont *sous-optimaux* d'un point de vue théorique, c'est-à-dire que la convergence de la solution n'est garantie que vers le *minimum local le plus proche de la configuration initiale des variables*. La solution est donc extrêmement sensible au choix de la configuration initiale. Mais ils ont à leur avantage une rapidité bien plus importante que celle des algorithmes stochastiques.
- ◆ Les algorithmes de relaxation stochastiques de type *recuit simulé* ([Geman84], [Kirkpa83]) sont théoriquement les meilleurs car la convergence vers un minimum global de la fonction d'énergie est théoriquement assuré, quelle que soit la configuration de départ. Mais il s'agit bien d'une preuve *théorique* de convergence : le minimum global de la fonction d'énergie n'est vraiment atteint qu'au prix d'un temps de calcul infini... Ils ne sont pas pour autant inutilisables : en pratique, les méthodes stochastiques "tronquées" et modifiées, bien que toujours assez lentes, permettent de trouver des solutions bien meilleures que celles proposées par les techniques déterministes. De plus, la qualité de la solution est indépendante de la configuration initiale des variables.

Voici donc le dilemme : en théorie, on est tenté d'utiliser les techniques stochastiques ; en pratique, on doit se contenter le plus souvent des méthodes d'optimisation déterministes... Mais de *quelle* pratique parle-t-on? On se réfère bien sûr à la pratique classique des calculateurs numériques séquentiels. Le présent chapitre a comme but de montrer quelles seraient les *fonctions de base* d'un processeur totalement dédié au *recuit simulé*. Le chapitre suivant en présentera une réalisation *pratique* – et qui, comme on pouvait s'y attendre, n'est ni numérique ni séquentielle, mais (essentiellement) *analogique et parallèle*.

2. Algorithmes stochastiques

2.1 Introduction

Les algorithmes de relaxation stochastique de type recuit simulé partent d'une configuration initiale donnée du champ d'étiquettes et s'arrangent ensuite pour générer à partir de celle-ci une suite qui s'approche plus ou moins rapidement du *mode* ou *état fondamental* de la fonction d'énergie U à minimiser. En termes plus formels, ces algorithmes, qui s'inspirent fortement de la physique statistique, peuvent être vus comme la combinaison de deux procédures que l'on détaillera par la suite :

- (a) Une procédure dite *d'échantillonnage dynamique* visant à atteindre l'équilibre thermodynamique des variables du champ d'étiquettes à chaque palier de *température*. Plus précisément encore, la procédure d'échantillonnage¹⁸ vise la *distribution de Gibbs à température T* :

$$G_T(E = e) = \frac{1}{Z_T} \exp\left(\frac{-U(e)}{T}\right)$$

- (b) Une procédure (ou schéma) de *refroidissement* plus ou moins optimale -le *recuit simulé* à proprement en parler : cette expression désigne une loi de décroissance continue ou par paliers de la température permettant d'atteindre une assez bonne solution du problème en un temps raisonnable.

L'idée sous-jacente est que si pour toute température l'équilibre thermodynamique peut être atteint - grâce à la procédure d'échantillonnage (a) -, alors à très basse température seules les configurations d'énergie minimale du système auront une probabilité non négligeable d'apparaître (la distribution de Gibbs favorise toujours les configurations qui minimisent la fonction d'énergie ; à la limite de température nulle, seuls les *modes fondamentaux* du système ont une probabilité non nulle d'apparaître). Malheureusement il est très coûteux - voire impossible - de générer *directement* un échantillon suivant la distribution de Gibbs à très basse température. On procède alors de façon progressive, par *recuit simulé* (b). L'idée, comme on l'a dit, est directement inspirée de la physique statistique (et de la métallurgie) : lorsqu'un matériau cristallin est *recuit* lentement, il est possible d'obtenir des états très ordonnés qui correspondent à des énergies proches de l'état fondamental. Au contraire, si le refroidissement est brutal, alors il est très vraisemblable que le cristal présente des défauts et que son énergie potentielle soit piégée dans un minimum local. Nous allons par la suite discuter en détail des points (a) et (b), dans le §2.2 et §2.3 respectivement.

¹⁸ Le mot "échantillonnage", dans ce contexte, désigne la fabrication d'un échantillon tiré d'une loi de probabilité spécifiée et non pas, comme souvent, la mesure d'une grandeur physique dépendant de variables continues spatio-temporelles.

2.2 Les procédures d'échantillonnage dynamiques

Les méthodes d'échantillonnage ou méthodes de *Monte Carlo* [Gidas91] s'attaquent au problème suivant : étant donné une mesure de probabilité π dans l'espace des configurations d'étiquettes Ω_E , comment générer des échantillons $e \in \Omega_E$ (réalisations du champ d'étiquettes) suivant cette loi?

Les méthodes de Monte Carlo peuvent être rangées dans deux catégories : les méthodes *statiques* et les méthodes *dynamiques*. Les premières consistent à générer une séquence d'échantillons *statistiquement indépendants* de la loi recherchée. Elles sont pourtant inadaptées à la plupart de cas pratiques rencontrées en physique par exemple (systèmes à très grand nombre de variables couplées suivant la distribution de Gibbs). Les méthodes de *Monte Carlo dynamiques* procèdent de façon plus subtile : un processus stochastique (n'ayant pas nécessairement d'équivalent réel) est inventé pour le besoin du problème, de telle sorte que seule la distribution π recherchée en soit la loi d'équilibre correspondante. Le processus stochastique est simulé sur ordinateur en partant d'une configuration aléatoire : au fur et à mesure de la simulation, le système tend *naturellement* vers son état d'équilibre. En général, le processus stochastique choisi est une *chaîne de Markov* (à ne pas confondre avec le *champ de Markov* vu dans le Chap.I.§3, qui, lui, rend compte des propriétés *spatiales* du champ d'étiquettes).

2.2.1 Chaînes de Markov. Théorème d'échantillonnage dynamique.

Un théorème très important montre que si le processus stochastique choisi est une chaîne de Markov homogène, irréductible et apériodique, admettant une distribution stationnaire π , alors la chaîne converge naturellement vers cette distribution quelle que soit la configuration initiale. Précisons ces concepts par un bref rappel des propriétés des chaînes de Markov (pour plus de détails, voir [Geman84]).

Définition 1 Une *chaîne de Markov* discrète dans l'espace de configurations Ω_E , est une suite de variables aléatoires $\{E_0, E_1, E_2, \dots\}$ à valeurs dans Ω_E telle que la probabilité d'avoir $E_{n+1}=e_{n+1}$ ne dépend que de la valeur du champ à l'instant précédant¹⁹ $E_n=e_n$. Plus précisément, une chaîne de Markov est définie par :

- Une distribution de probabilités initiale $p^0(e) : Pr(E_0=e)=p^0(e), \forall e \in \Omega_E$.
- Une suite de matrices de *transition* $P^n=(p^n_{xy})$ telles que $p^n_{xy}=Pr(E_{n+1}=y/E_n=x)$, où x et y appartiennent à Ω_E .

¹⁹ En toute rigueur, cette probabilité dépend d'un *voisinage temporel passé* $\{E_{n-1}, E_{n-2} \dots E_{n-k}\}$; mais nous allons nous limiter par la suite au cas où ce voisinage se réduit à E_{n-1} .

Les éléments de la matrice de transition P^n (appelés *probabilités de transition ou de passage*) sont positifs ou nuls, et l'on a nécessairement pour toute configuration de départ $x \in \Omega_E$ la relation : $\sum_{y \in \Omega_E} p_{xy}^n = 1$ (on dit que la matrice P^n est *stochastique*).

Définition 2 Une chaîne de Markov est dite *homogène* si la matrice de transition P^n est indépendante de n (elle sera noté simplement P). Nous allons nous intéresser uniquement aux chaînes de Markov homogènes.

La matrice de transition gère l'évolution de la *distribution de probabilités* du champ (noté p^n à l'étape n) ; ainsi par exemple, la distribution de probabilités à l'étape $n+1$ est liée à celle de l'étape n par la relation :

$$\forall y \in \Omega_E, \Pr(E_{n+1} = y) = \sum_{x \in \Omega_E} \Pr(E_n = x) \cdot p_{xy}$$

L'expression matricielle équivalente est : $p^{n+1} = Pp^n$, (on considère ici p^n comme un vecteur à valeurs réelles de dimension égale au cardinal de Ω_E). On définit également la probabilité de passage d'une configuration à une autre en un nombre k de pas par :

$$p_{xy}^{(k)} = \Pr(E_{n+k} = y / E_n = x).$$

La matrice de transition ou de passage correspondante est $P^{(k)} = P^k$; la distribution de probabilités du champ à l'étape $n+k$ est lié à celle de l'étape n selon : $p^{n+k} = P^k p^n$.

Définition 3 Une distribution de probabilité π sera dite *stationnaire* pour la chaîne considérée si et seulement si :

$$\forall y \in \Omega_E, \pi(y) = \sum_{x \in \Omega_E} \pi(x) \cdot p_{xy},$$

Matriciellement $\pi = P\pi$, c'est à dire que la distribution stationnaire *est vecteur propre* de la matrice de transition.

Remarque : Une *chaîne* de Markov est dite stationnaire si les probabilités *a priori* p^n des états à l'instant n sont indépendants de n . Soulignons alors que l'homogénéité et la stationnarité d'un processus stochastique sont deux caractères distincts : le processus peut avoir une *évolution* régulière (et donc être homogène) et être tel que cette évolution l'éloigne de sa configuration initiale (le processus n'est pas stationnaire).

Définition 4 Une distribution π sera *a fortiori* stationnaire si elle vérifie la condition de *bilan détaillé* :

$$\forall (x,y) \in \Omega_E \times \Omega_E, \pi(x)p_{xy} = \pi(y)p_{yx}$$

Remarque : La condition de bilan détaillé traduit la symétrie par inversion du temps dans la plupart des systèmes physiques (réversibilité macroscopique). Dans un tel système à l'équilibre thermodynamique, la transition de x vers y se fait, en moyenne, le même nombre de fois que de y vers x (on peut dire aussi en appliquant l'hypothèse d'ergodicité que dans un ensemble composé d'un grand nombre de systèmes identiques à l'équilibre, le nombre moyen de systèmes effectuant la transition de x vers y à l'instant t est égal à celui effectuant la transition inverse). Cette condition implique bien la stationnarité des grandeurs moyennes du système, dont en particulier l'énergie.

Définition 5 Une chaîne de Markov est dite *irréductible* s'il est toujours *potentiellement* possible de passer d'une configuration du système à une autre en un nombre fini d'étapes :

$$\forall (x,y) \in \Omega_E \times \Omega_E, \exists n \in \mathbb{N}^* : p_{xy}^{(n)} > 0$$

Définition 6 On définit la *période* de la configuration particulière $x \in \Omega_E$ comme étant le plus grand commun dénominateur (PGCD) des nombres n tels que $p_{xx}^{(n)} > 0$; on dit que la chaîne de Markov est *apériodique* si elle n'admet pas de période quelle qu'elle soit la configuration choisie (i.e. pour tout $x \in \Omega_E$, la période est égale à 1). En particulier, une chaîne de Markov admettant les transitions nulles ($p_{xx}^{(1)} > 0$) est apériodique.

On est enfin en mesure d'énoncer le théorème fondamental qui va nous permettre de construire un algorithme d'échantillonnage dynamique :

Théorème de "stationnarisation" Soit $\{E_n\}_{n \in \mathbb{N}}$ une chaîne de Markov *homogène*, *irréductible* et *apériodique*. Si elle admet une *distribution stationnaire* π , alors celle-ci est non seulement unique mais de plus la distribution de probabilité de la chaîne converge vers la distribution d'équilibre π , et cela *indépendamment* de la distribution initiale [Chung67] :

$$\forall x \in \Omega_E, \lim_{n \rightarrow +\infty} p_{xy}^{(n)} = \pi(y).$$

(la chaîne de Markov se "stationnarise" de façon asymptotique sur la distribution π .)

Remarquons que la distribution initiale peut être de la forme : $p^0(E=e) = \delta(e=e_0)$, c.à.d. que l'on peut *initialiser* la chaîne avec une configuration bien déterminé au départ. Alors le théorème ci-dessus prouve que la *distribution de probabilité* à l'instant n converge vers π indépendamment du choix de la configuration initiale.

On voit alors comment il faut procéder pour obtenir un échantillonneur dynamique de Monte Carlo : il suffit de construire, à partir de la distribution π recherchée, une matrice de transition P satisfaisant aux conditions du théorème. La simulation du comportement dynamique de la chaîne ne présente ensuite aucune difficulté de principe.

On présente dans ce qui suit deux techniques permettant de construire une matrice de transition P satisfaisant aux conditions du théorème. La première donne lieu à la procédure *d'échantillonnage dynamique de Metropolis* ; la seconde à la procédure *d'échantillonnage de Gibbs*.

2.2.2 Echantillonneur de Metropolis (ou *dynamique de Metropolis*).

Une méthode très générale pour construire des matrices de transition satisfaisant aux conditions du théorème a été esquissée originellement par [Metrop53] dans le cadre de l'étude des propriétés thermodynamiques des systèmes à plusieurs particules.

Condition de stationnarité et d'homogénéité. Dans cette méthode, la *stationnarité* de la distribution est assurée par la condition suffisante quoique plus restrictive du *bilan détaillé*. Cette condition est néanmoins plus facile à vérifier : la méthode de Metropolis-Hastings [Hasti70] est une technique générale permettant de s'y tenir à partir de n'importe quelle matrice stochastique. L'idée est la suivante : soit $Q=(q_{xy})_{(x,y) \in \Omega_x \times \Omega}$ une quelconque matrice de transition sur Ω_E . Cette matrice sera dite de *proposition*, puisqu'elle servira à proposer des transitions qui seront ou non acceptées suivant les probabilités tabulées dans la *matrice d'acceptation* $A=(a_{xy})_{(x,y) \in \Omega_x \times \Omega}$. Plus précisément, une transition quelconque proposée, par exemple de x vers y sera *acceptée* avec la probabilité $0 \leq a_{xy} \leq 1$ et *rejetée* avec la probabilité $1-a_{xy}$ (auquel cas on procède à une transition nulle $x \rightarrow x$). Les éléments de la matrice de transition $P=(p_{xy})_{(x,y) \in \Omega_x \times \Omega}$ ainsi définie s'écrivent alors :

$$\forall (x,y) \in \Omega_E \times \Omega_E, \begin{cases} p_{xy} = q_{xy} a_{xy} \\ p_{xx} = q_{xx} + \sum_{y \neq x} q_{xy} \cdot (1 - a_{xy}) \end{cases}$$

Il est facile de voir que la condition de bilan détaillé est observée si et seulement si :

$$\forall (x,y) \in \Omega_E \times \Omega_E, \frac{a_{xy}}{a_{yx}} = \frac{\pi_y q_{yx}}{\pi_x q_{xy}}$$

Il suffira, pour satisfaire cette condition, de prendre : $a_{xy} = f\left(\frac{\pi_y q_{yx}}{\pi_x q_{xy}}\right)$, avec f une

fonction quelconque de R^+ dans $[0,1]$ vérifiant pour tout $z \in R^+$ la condition : $\frac{f(z)}{f(z^{-1})} = z$.

Remarque (importante). Dans le cas qui nous intéresse, la distribution stationnaire recherchée π est la distribution de Gibbs à température T :

$$\pi(x) = G_T^U(x) = \frac{1}{Z_T} \exp\left(\frac{-U(x)}{T}\right)$$

On remarque alors que la fonction de partition Z_T a disparu de l'expression de la loi d'acceptation :

$$a_{xy} = f\left(\frac{G_T^U(y)q_{yx}}{G_T^U(x)q_{xy}}\right) = f\left(\exp\left[\frac{-\Delta U_x^y}{T}\right] \cdot \frac{q_{yx}}{q_{xy}}\right),$$

où $\Delta U_x^y \equiv U(y) - U(x)$ (on appelle parfois *force* la quantité $F_x^y \equiv -\Delta U_x^y$). Par la suite on confondra toujours π et G_T .

Si l'on prend en outre une matrice de proposition Q *symétrique* (ce qui n'est pas une nécessité, mais c'est le choix qui sera fait par la suite), alors l'expression de la probabilité d'acceptation se réduit encore plus : $a_{xy} = f\left(\exp\left[\frac{-\Delta U_x^y}{T}\right]\right)$.

Enfin, plusieurs choix sont possibles pour la fonction f ; le choix de la fonction *maximale* satisfaisant la condition énoncé plus haut : $f(z) = \min(1, z)$ est attribué à Metropolis [Metrop53], et donne lieu à la *dynamique (d'évolution) de Metropolis*. La probabilité d'acceptation de la transition proposée $x \rightarrow y$ vaut alors (voir fig.II.1 et procédure P.1) :

$$a_{xy} = \begin{cases} 1 & \text{si } U(y) < U(x) \\ \exp\left[-\frac{\Delta U_x^y}{T}\right] & \text{dans le cas contraire.} \end{cases}$$

Un autre choix consiste à prendre : $f(z) = \frac{z}{1+z}$; il donne lieu à la *dynamique de Barker* [Gidas91]. Si la distribution à échantillonner est la distribution de Gibbs à température T , et si l'on choisit une matrice de tentation symétrique, alors l'application de la dynamique de Barker donne lieu à ce que l'on appelle *algorithme du thermostat* (ou *Heat-Bath*) - voir procédure P.2). Dans ce cas, la probabilité d'acceptation devient :

$$a_{xy} = \frac{1}{1 + \exp\left[\frac{\Delta U_x^y}{T}\right]}$$

Il s'agit de la *loi sigmoïde* que l'on tentera de générer par des moyens *optoélectroniques* (cf. Chap.III, §5.3).




Fig.II.1 : Probabilité d'acceptation pour la dynamique de Metropolis.




Fig.II.2 : Probabilité d'acceptation sigmoïde pour la dynamique de Barker (loi du Thermostat). Remarque : plus la force est grande, et plus elle "tire" vers le nouvel état proposé.

Condition d'irréductibilité et d'apériodicité. On a donc vu comment la méthode de *Metropolis-Hasting* permet de construire une matrice de transition vérifiant la condition de bilan détaillé relativement à une distribution donnée (et donc d'assurer la stationnarité de cette distribution par rapport à la chaîne de Markov correspondante) à partir d'une matrice de transition *quelconque* ; cependant, pour appliquer le théorème de stationnarisation, il ne faut pas oublier la condition *d'irréductibilité* et *d'apériodicité* de la matrice de transition. Une façon de s'assurer de ces propriétés consiste à procéder comme suit²⁰ : considérons tout d'abord les transitions ne modifiant la configuration courante *qu'en un seul site s* (les calculateurs séquentiels sont bien adaptés pour simuler ce type de dynamique ; on verra au §2.2.5 une alternative adaptée aux calculateurs parallèles, mais le cas séquentiel est très instructif dans un premier abord). Soit la matrice de proposition locale Q^s dont les éléments sont définis par :

²⁰ La stratégie qui sera exposée par la suite, et qui consiste à s'intéresser seulement aux transitions qui proposent le changement d'un *seul* site à chaque étape porte le nom de *dynamique de Glauber* ou *Single-spin-flip*. Il existe d'autres stratégies, par exemple la *dynamique de Kawasaki* ou *pair-interchange dynamic*, qui propose à chaque étape la transposition d'une *paire* de sites. Notre intérêt pour la dynamique du *single-spin-flip* est justifiée par le fait qu'elle engendre naturellement des opérations *locales* ; ceci est une condition *nécessaire* pour l'implantation de la procédure dans une machine parallèle de type SIMD - mais elle n'est pas suffisante, cf §2.2.5.

$$\forall (x,y) \in \Omega_E \times \Omega_E, q_{xy}^s = \begin{cases} \frac{1}{G_E}, & \text{si } x \text{ et } y \text{ coïncident sur toute la grille } S \text{ sauf en } s, \\ 0 & \text{sinon.} \end{cases}$$

Etant donnée une configuration courante x , la matrice de tentation locale Q^s propose donc de façon *équiprobable* toutes les transitions vers les configurations coïncidant avec x sur toute la grille S , sauf sur le site s en question.

Dynamique de **Metropolis** pour la mise à jour du site s :

Soit x l'état courant du champ et g_x le label courant au site s ;

- Proposer un nouveau label g_y choisi au hasard selon une loi uniforme sur G_E .
- Calculer la force *locale* $F(s)$ définie selon :

$$F(s) = -\Delta U(s) = -[U(x/x(s)=g_y) - U(x/x(s)=g_x)],$$

- Si $F(s) \geq 0$, alors on accepte le changement : $x(s) \leftarrow g_y$.
- Si $F(s) < 0$, alors on accepte le changement avec une probabilité $\exp(F(s))$.

P.1 : Procédure de mise à jour locale selon la dynamique de Metropolis (matrice de tentation locale choisie équiprobable du label).

En appliquant la méthode de Metropolis-Hasting on peut construire une matrice de transition locale P^s qui sera stationnaire vis à vis de π (voir les procédures *P.1* et *P.2* pour la mise à jour de sites selon la dynamique de Metropolis et du Thermostat respectivement) ; mais il est manifeste que cette matrice n'est pas irréductible (elle ne permet pas de passer d'un état x à un autre état quelconque y différent de x pour un site autre que s). Pour cela il faut choisir une *stratégie de parcours* des sites, définissant une matrice de transition *globale* irréductible.

Dynamique du **Thermostat** pour la mise à jour du site s :

Soit x l'état courant du champ et g_x le label courant au site s :

- Proposer un nouveau label g_y choisi au hasard selon une loi uniforme sur G_E .
- Calculer la *force locale* $F(s)$ définie selon :

$$F(s) = -\Delta U(s) = -[U(x/x(s)=g_y) - U(x/x(s)=g_x)],$$

- *Accepter* ce changement avec une probabilité (loi sigmoïde) :

$$\Pr[x(s) \leftarrow g_y] = \frac{1}{1 + \exp\left[\frac{-F(s)}{T}\right]}$$

P.2 : Procédure de mise à jour locale selon la dynamique du Thermostat. (matrice de tentation locale choix équiprobable du label).

Voici deux stratégies de parcours possibles :

1) *Stratégie de parcours aléatoire.* Si $N=nxm$ est le nombre de sites de la grille S , alors on peut définir la matrice de transition :

$$P = \frac{1}{N} \sum_{s \in S} P^s$$

Cela revient dans la pratique à réaliser un tirage aléatoire du site concerné par la transition selon une distribution équiprobable sur l'ensemble des sites de la grille. La matrice P est irréductible, puisqu'elle permet de réaliser (potentiellement) la transition entre deux configuration quelconques au plus en N opérations. La distribution π est toujours stationnaire, puisqu'elle l'est pour chacune des matrices de transition locales. Enfin, elle est apériodique puisque toutes les transitions *nulles* sont permises. Les conditions du théorème de stationnarisation sont remplies. La procédure d'échantillonnage complète est explicitée dans l'encadré *P.3*.

Procédure Echantillonnage_Aléatoire (x_o, T).

- On part de la configuration initiale d'étiquettes $x_o \in \Omega_E$;
- On répète *indéfiniment* :
 - Choisir un site s au hasard.
 - Mettre à jour ce site selon la dynamique de Metropolis (*P.1*) ou du Thermostat (*P.2*) à température T .

*P.3 : Procédure d'échantillonnage de Metropolis (ou du Thermostat) à **parcours aléatoire** des sites pour la construction d'une chaîne de Markov convergeant vers la distribution de Gibbs à température T ("thermalisation").*

2) *Stratégie de parcours séquentiel périodique* Une autre stratégie consiste à parcourir la grille S selon une séquence prédéterminée $\{s_0, s_1, s_2, \dots, s_N\}$ sans omettre aucun site. La séquence est souvent périodique et de période égale au nombre de sites de l'image : on parle dans ce dernier cas de *balayage* des sites. La chaîne de Markov associée n'est plus homogène puisque la matrice de transition P^n (créée à partir de Q^n par la procédure de Metropolis-Hasting) dépend du site considéré s_n à l'étape n . Par contre, la sous-chaîne extraite en prenant un échantillon de la chaîne à chaque fin de balayage (ou un multiple quelconque) est homogène. On vérifie alors que la matrice de transition résultante :

$$P = \prod_{n=0}^{N-1} P^{s_n}$$

est apériodique, irréductible et admet π comme distribution stationnaire (la condition de bilan détaillé n'est pas nécessairement remplie pour la matrice de transition globale, mais π est stationnaire car il s'agit d'un vecteur propre du produit des matrices de transition

Procédure Echantillonnage_Parcours_Périodique (x_o, T).

- On part de la configuration initiale d'étiquettes $x_o \in \Omega_E$;
- On répète *indéfiniment* :
 - Choisir un site après l'autre selon un parcours séquentiel de l'image.
 - Mettre à jour ce site selon la dynamique de Metropolis (*P.1*) ou du Thermostat (*P.2*) à température T .

*P.4 : Procédure de Metropolis (ou du Heat-Bath) avec **balayage séquentiel** des sites pour la construction d'une chaîne de Markov convergeant à l'infini vers la distribution de Gibbs à température T .*

locales). Le balayage le plus simple suit en général un ordre *lexicographique*, mais d'autres parcours sont possibles pour éviter autant que possible les artefacts de convergence²¹ (balayage *chaîné* par exemple - lexicographique en aller-retour). On appellera *itération* la mise à jour complète du champ d'étiquettes (balayage de l'image toute entière).

2.2.3 L'échantillonneur de Gibbs.

Condition de stationnarité et d'homogénéité. Introduit par les frères Geman [Geman84], l'échantillonneur de Gibbs (*Gibbs Sampler*) ne s'appuie pas sur la condition de bilan détaillé, mais plutôt sur la *distribution conditionnelle locale* caractérisant le champ de Markov dont est constituée la chaîne de Markov²². En effet, les éléments de la matrice de transition locale P^s sont définis par :

$$\forall (x,y) \in \Omega_{Ex} \Omega_E, p_{xy}^s = \Pr(E(s) = y(s) / E(r) = x(r), r \neq s),$$

si x et y ne diffèrent que par le site s , et 0 sinon. On remarque que la probabilité de transition locale ne dépend plus de l'état courant du site s , et que la chaîne ainsi construite est *homogène*, ce qui n'était pas le cas directement dans la méthode de Metropolis (la probabilité d'acceptation a_{xy} dépendait du quotient $\pi(x)/\pi(y)$, ou de la différence d'énergie $U(x)-U(y)$ entre l'état courant x et le nouvel état proposé y dans le cas où π s'assimile à la distribution de Gibbs).

Si l'on s'intéresse au problème de régularisation d'images par champs de Markov - et en vertu du théorème de Hammersley-Clifford (Chap.I,§3.2) - l'expression de la probabilité conditionnelle locale (et donc p_{xy}^s) prend alors la forme Gibbsienne suivante (le paramètre de température T est introduit pour pouvoir réaliser le recuit - voir plus loin, §2.3) :

$$p_{xy}^s = \frac{1}{Z_s^T(y,o)} \exp\left(-\frac{U_s(y,o)}{T}\right) \equiv G_U^T(E(s) = y(s) / E(r) = x(r), r \neq s),$$

où Z_s^T et U_s sont respectivement la fonction de partition et l'énergie *locales* du champ de Markov couplé $X=\{E,O\}$ (voir remarque au Chap.I,§4.1), associées au site s :

$$U_s(y,o) = \sum_{c \in C_x / s \in c} V_c(y,o) \text{ et } Z_s^T(y,o) = \sum_{a \in G_E} \exp\left[-\frac{U_s(y,o|_{y(s)=a})}{T}\right].$$

Dans ces conditions, la distribution de Gibbs (à température T) est bien *stationnaire* pour la chaîne de Markov engendrée (et cela même si la condition de bilan détaillée n'est pas respectée). En effet, supposons que la distribution à l'étape n soit la distribution de Gibbs

²¹ car dans la pratique la chaîne est *tronquée* (on parle de chaînes de Markov à horizon fini).

²² on considère que ces propriétés statistiques "intrinsèques" du champ sont indépendantes de n .

à température T , i.e : $\forall x \in \Omega_E, \Pr(E_n = x) = G_U^T(x)$. Après la mise à jour locale du site s , on aura :

$$\begin{aligned} \Pr(E_{n+1} = x) &= \Pr(E_{n+1}(s) = x(s) / E_n(r) = x(r), r \neq s) \cdot \Pr(E_n(r) = x(r), r \neq s), \\ &= G_U^T(E(s) = x(s) / E(r) = x(r), r \neq s) \cdot G_U^T(E(r) = x(r), r \neq s) = G_U^T(x), \end{aligned}$$

car la mise à jour des sites se fait précisément selon la loi de distribution de Gibbs conditionnelle locale. On vient donc de montrer que la distribution de Gibbs est vecteur propre de la matrice de transition de l'échantillonneur de Gibbs : elle est donc stationnaire par rapport à la chaîne de Markov.

La procédure de mise à jour locale pour l'échantillonneur de Gibbs sur champ de Markov est esquissée dans l'encadré P.5.

Procédure de Gibbs pour la mise à jour du site s à température T :

Soit x l'état courant du champ d'étiquettes ;

- Pour chaque $a_i \in G_E$, calculer la probabilité conditionnelle locale p_i :

$$p_i = \Pr[E(s) = a_i / E(r) = x(r), r \in V(s)] = \frac{1}{Z_s^T(y, o)} \exp\left[-\frac{U_s(y, o)}{T}\right],$$

où $y(s) = a_i$ et $y(r) = x(r)$ pour $r \neq s$.

- Choisir au hasard la nouvelle étiquette pour s suivant cette distribution ; en pratique cela revient à tirer un nombre $\mu \in [0, 1]$ selon une loi uniforme et la nouvelle étiquette attribuée à s sera a_j correspondant au plus petit indice j tel que $\sum_{n=1}^j p_n > \mu$.

P.5 : Remise à jour locale par l'échantillonneur de Gibbs dans le cas d'un champ d'étiquettes E markovien. On remarquera que la probabilité de transition locale ne dépend pas de la valeur du label courant au site s .

Condition d'irréductibilité et d'apériodicité. Pour construire une matrice de transition globale qui soit irréductible et apériodique, il suffit de procéder comme auparavant, on choisissant soit une stratégie de parcours aléatoire, soit un balayage séquentiel périodique (voir encadré P.6).

Remarque : une propriété intéressante également démontrée dans [Geman84] est que la chaîne de Markov *non homogène* engendrée par l'échantillonneur de Gibbs pour un parcours séquentiel des sites converge *en distribution* vers π et que pour

toute fonction mesurable f sur Ω_E (en particulier l'énergie) la loi des grand nombres suivante est vérifiée :

$$\lim_{n \rightarrow +\infty} \frac{1}{n} \sum_{k=1}^n f(E(k)) = \langle f(E) \rangle_{\pi} = \sum_{e \in \Omega_E} \pi(e) \cdot f(e)$$

Cette propriété exprime l'égalité entre la moyenne ergodique (premier terme) et l'espérance de la variable aléatoire $f(E)$ (deuxième terme), propriété qui peut être exploitée lors de la construction d'estimateurs bayésiens classiques (MPM ou MF par exemple -voir Chap.I, §2.2 et remarque §4).

Procédure **Thermalisation_Gibbs** (x_o, T).

- On part de la configuration initiale d'étiquettes $x_o \in \Omega_E$;
- On répète *indéfiniment* :
 - Choisir les sites selon un parcours séquentiel ou aléatoire.
 - Mettre à jour ce site selon la procédure de Gibbs (P.5) à température T .

P.6 : Procédure de thermalisation (ou échantillonnage) de Gibbs avec balayage séquentiel ou aléatoire des sites.

Enfin, il est intéressant de noter que si le champ de Markov est à valeurs *binaires* ($G_E = \{0,1\}$) alors la matrice de transition dans le cas de l'échantillonneur de Gibbs coïncide avec celle de l'algorithme du Thermostat. En particulier, la *force* ne dépend pas de la valeur courante du site considéré, mais seulement de celles de ses voisins (*cf.* exemple débruitage d'images binaires au §2.2.5).

Nous allons désormais porter toute notre attention au cas particulier des champs d'étiquettes binaires, dont la dynamique est suffisante pour traiter le modèle d'Ising 2D, le problème de la restauration d'images binaires, le B-codage et enfin le modèle de détection du mouvement qui sera exposé au Chap.IV.

2.2.4 Régime transitoire

Quel que soit l'état initial du champ d'étiquettes, on peut être assuré que si la procédure d'échantillonnage (Metropolis ou Gibbs) est conforme aux prescriptions énoncées dans le théorème de stationnarisation, alors la chaîne de Markov engendrée converge vers la distribution d'équilibre... au bout d'un nombre infini d'itérations! Dans la pratique toutefois, la chaîne de Markov sera nécessairement *tronquée*. Il faut pouvoir en mesurer les conséquences ; en particulier, si le champ n'est pas initialement à l'équilibre, alors il serait utile de connaître la *durée du régime transitoire* (ou de façon équivalente la *rapidité de convergence*) avant qu'il n'atteigne une configuration proche de

l'équilibre - et pouvoir fixer ainsi un nombre d'itérations raisonnable qui ne soit ni trop petit ni trop grand.

Remarque : Le problème est en vérité très délicat ; sans rentrer dans les détails (on pourra trouver une discussion intéressante dans [Sokal89]), on montre que l'on peut obtenir au mieux une borne supérieure pour la durée du régime transitoire à partir de la connaissance du *temps exponentiel d'autocorrelation* défini selon :

$$\tau_{\text{exp}} = \sup_f \tau_{\text{exp},f}, \text{ avec } \tau_{\text{exp},f} = \limsup_{t \rightarrow \infty} \frac{t}{-\log(\rho_{ff}(t))}$$

où f est une observable quelconque du système à valeurs réelles (par exemple *l'énergie*) et ρ_{ff} sa fonction d'autocovariance normalisée. Cette dernière décroît typiquement de *façon exponentielle* (selon $e^{-t/\tau}$) ; τ_{exp} représente donc la constante de temps de l'observable "la plus lente" du système (pour des chaînes à temps discret, τ_{exp} correspond à un *nombre d'itérations* entier). Par exemple, si l'on attend $10 \cdot \tau_{\text{exp}}$ alors le biais entre la valeur de n'importe quelle observable et sa valeur moyenne à l'équilibre est au plus égale à e^{-10} ($\approx 4,5 \times 10^{-5}$). Malheureusement la connaissance exacte de τ_{exp} s'avère en général impossible. On peut essayer tout au plus d'estimer l'autocovariance normalisée sur quelques observables qui *devraient a priori* fluctuer lentement -mais le choix des observables peut s'avérer maladroit. D'autre part, il se peut bien évidemment que la convergence réelle soit beaucoup plus rapide qu'il n'en résulte de l'estimation précédente. On procède alors de *façon empirique*, en traçant plusieurs observables en fonction du temps et en notant la longueur apparente du régime transitoire²³. C'est ce que nous avons fait pour le modèle de la restauration d'images binaires.

Le cas du débruitage d'images binaires est certainement un cas d'école (Chap.I.§5.1) ; il n'en sera pas moins utile par la suite. En effet, la fonction d'énergie à minimiser dans le cas de la restauration d'images binaires contient tous les termes nécessaires pour rendre compte du problème plus complexe de la détection du mouvement (Chap.IV). Autrement dit, le problème de la détection du mouvement peut être vu comme un celui de la restauration d'un champ binaire bruité - à ceci près que celui-ci résulte d'un *prétraitement spatio-temporel* de la séquence d'images réelles (champ binaire $b(t)$, cf. Chap.IV, §6.3.2).

Nous avons donc procédé à des simulations sur le modèle de la restauration d'images binaires dans le but d'estimer "expérimentalement" la longueur du régime transitoire avant que l'énergie - l'observable choisie - ne *semble* se stabiliser autour d'une valeur moyenne (fig.II.3). Dans l'exemple, l'image à restaurer est la lettre "E" bruitée, large de 24 pixels de côté. La taille correspond à celle de la matrice optoélectronique qui sera présentée au chapitre suivant (Chap.III), de sorte que l'étude que l'on fait ici aidera à la détermination des bons paramètres de l'expérience – cf. Chap.VI,§1.3).

²³ Il existe toujours le risque que le système soit bloqué temporairement dans une configuration transitoire de longue durée (état métastable).

On retrouve bien le fait que la durée du régime transitoire augmente quand T diminue, et croît rapidement à l'approche d'une transition de phase (phénomène connu sous le nom de *critical-slowning-down*). Nous avons effectué le même type de simulation en faisant varier la taille de l'image et la topologie du voisinage. La température critique (abscisse du point d'inflexion de la courbe *fig.II.4*) est sensiblement indépendante de la taille de l'image et ne varie que si l'on change les paramètres du modèle ou la topologie du voisinage. Ceci va nous permettre de fixer une fois pour toutes trois valeurs pour les paliers de température en étude : T_1 , $T_2 \approx T_c$ et T_3 (respectivement avant, pendant et après la transition de phase). Ces trois températures caractérisent des comportements différents de l'algorithme d'échantillonnage : pour une température supérieure à la température critique, la convergence se fait en moins d'une dizaine d'itérations, alors que pour des températures inférieures à celle-ci, la convergence prend au moins une vingtaine d'itérations (et bien plus pour des images larges, voir *fig.II.5*).

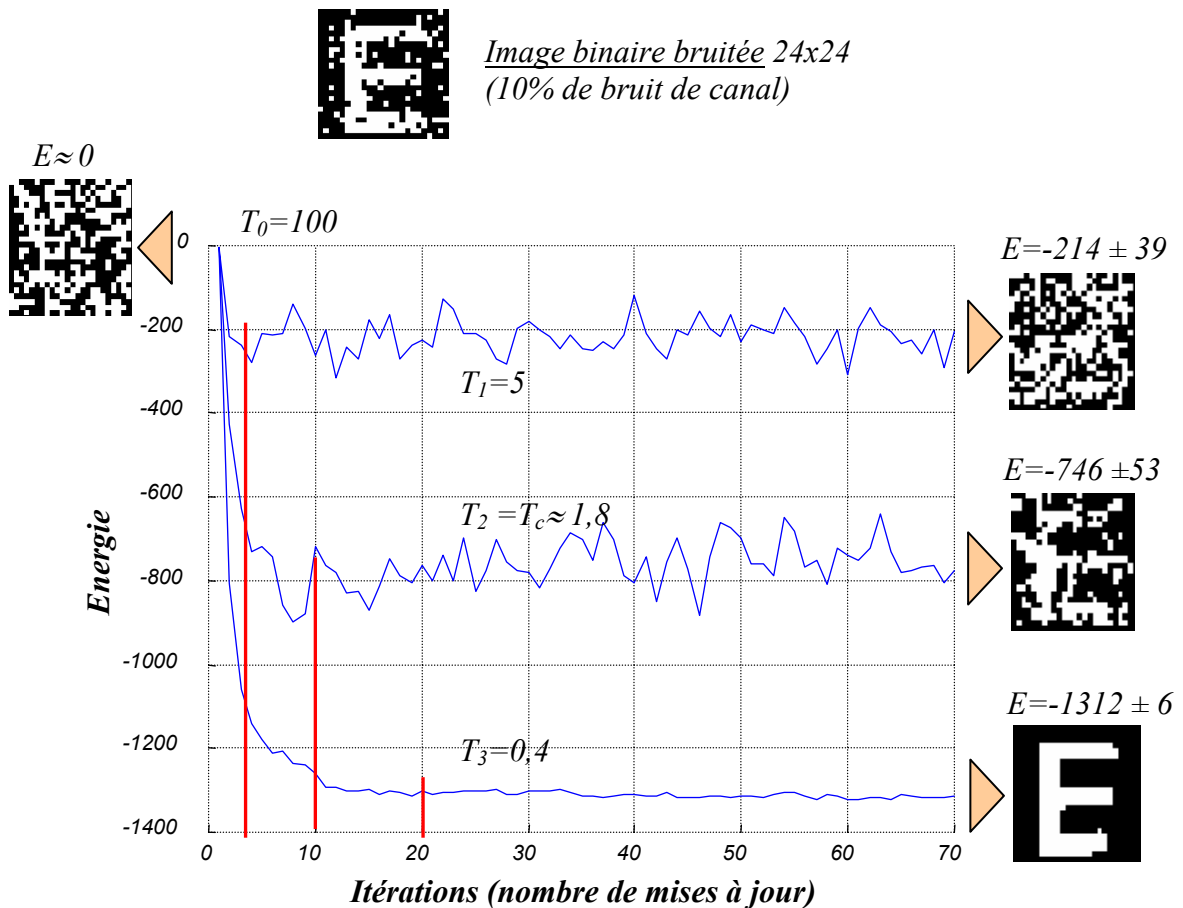


Fig.II.3 : Régime transitoire avant équilibre pour trois paliers de température (on part d'un champ à l'équilibre à température élevée $T=100$).

Remarque : La stratégie de balayage des sites - séquentielle périodique, aléatoire ou parallèle (cf.§2.2.5) - ne semble pas avoir d'influence significative sur les résultats de l'échantillonnage. Nous avons opté par la suite pour une stratégie de mise à jour parallèle dans nos simulations.

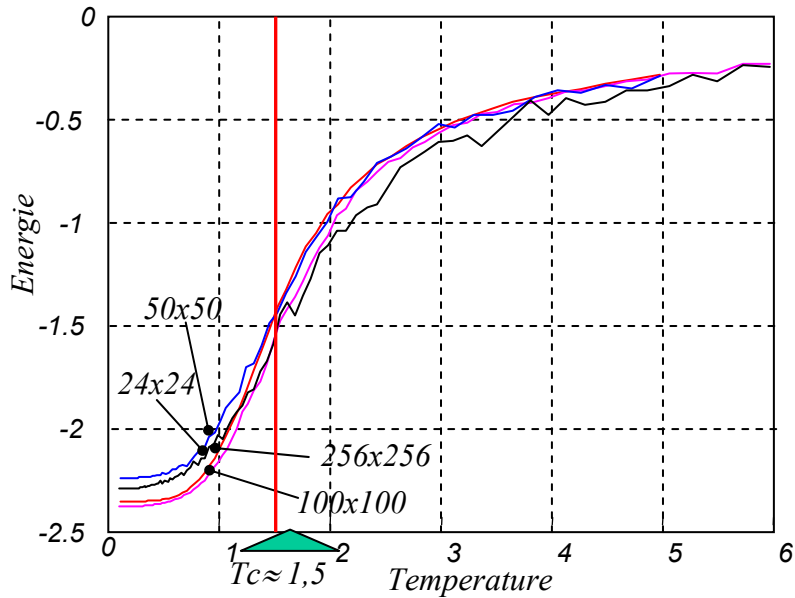


Fig.II.4 : Energie (normalisée) en fonction de la température pendant le recuit simulé pour différentes tailles de la grille (24^2 , 50^2 , 100^2 et 256^2). La température critique ne dépend pas de la taille de l'image, mais des seuls paramètres du modèle (ici $\beta_s = 1$, $\beta_o = 1$).




Fig.II.4 : Evolution de l'énergie (normalisée) pour différentes tailles de l'image (24^2 , 50^2 , et 256^2) en fonction du nombre de mises à jour complètes du champ d'étiquettes.

2.2.5 Parallélisation des procédures d'échantillonnage.

Il est possible d'adopter deux stratégies *complémentaires* de parallélisation pour accélérer la convergence des algorithmes d'échantillonnage :

- Chaînes de relaxation en parallèle. Cette classe regroupe des algorithmes à gros grain, où plusieurs unités de calcul exécutent indépendamment des processus de relaxation séquentiels [Aarts86]. Les différents processus explorent de façon concurrente l'espace des configurations et échangent périodiquement des informations afin d'accélérer (ou d'améliorer) la convergence. Ce genre d'algorithme se prête bien à l'implantation sur des machines parallèles à usage général de type MIMD (*Multiple Instructions, Multiple Data*).
- Réactualisation simultanée des sites. Les algorithmes appartenant à cette classe correspondent à un niveau de parallélisme à grain fin où plusieurs de sites sont mis à jour en parallèle (voire tous les sites en même temps). Une seule chaîne est générée, qui converge plus rapidement que son homologue séquentiel. Ces algorithmes sont adaptés à la mise en œuvre sur des machines possédant un grand nombre de processeurs à connexions locales fonctionnant en mode SIMD (*Single Instruction, Multiple Data*).

Dans le cadre de notre recherche sur les *processeurs optoélectroniques parallèles*, nous allons nous intéresser exclusivement à cette dernière approche. En traitement d'images, Geman & Geman [Geman84] ont été les premiers à proposer la réactualisation simultanée des sites par un ensemble de processeurs travaillant de manière *asynchrone*. Nous allons également nous restreindre au cas où les processeurs (également appelés *processeurs élémentaires* ou *PEs*) travaillent de façon *synchrone*.

Commençons par une remarque intéressante. La localité des transitions proposées (par l'échantillonneur de Metropolis ou de Gibbs) est susceptible de rendre également *local* le calcul de la différence d'énergie :

$$F_x^y = F(s) = -\Delta U_x^y = -\Delta U(s) = -[U(x/x(s) = g_x) - U(x/x(s) = g_y)],$$

à condition que l'étendue des interactions entre les différentes variables de la fonction d'énergie U à minimiser soit elle-même réduite (on parlera alors de *force locale*). C'est précisément le cas pour l'énergie d'un *champ de Markov* à voisinage réduit d'ordre 1 ou 2 (cf. Chap.I,§3).

Exemple : *Force locale dans le cas du débruitage d'images binaires.* L'énergie associée au problème de la restauration d'images binaires s'écrit (cf Chap.I,§5.1.1) :

$$U(e, o) = -\frac{\beta_s}{2} \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1)(2e(r) - 1) - \frac{\beta_o}{2} \sum_{s \in S} (2o(s) - 1)(2e(s) - 1)$$

La différence d'énergie ou *force locale* vaut alors (en supposant que l'étiquette courante du site s soit $e(s)=1$ et celle du nouvel état proposé soit $e(s)=0$) :

$$F_0^1(s) = -\Delta U(s) = -U(e, o / e(s) = 1) + U(e, o / e(s) = 0) = F_o(s) + F_s(s)$$

- Le premier terme ou *force locale de contrainte aux données* vaut alors :

$$F_o(s) = \beta_o(2o(s) - 1)$$

- De même, le deuxième terme ou *force spatiale de régularisation* vaut :

$$F_s(s) = \beta_s \sum_{r \in V(s)} (2.e(r) - 1),$$

La force locale qui "tire" de l'état courant 1 vers le nouvel état proposé 0 s'écrit finalement :

$$F_0^1(s) = \beta_o(2o(s) - 1) + \beta_s \sum_{r \in V(s)} (2.e(r) - 1),$$

(et l'on a bien sûr : $F_1^0(s) = -F_0^1(s)$). Soulignons que *dans cet exemple*, la force locale ne dépend pas de l'état *courant* au site considéré ; ceci est dû au fait que les variables sont *binaires* (cf §2.2.3).

La parallélisation massive de la mise à jour des sites n'est pas pour autant immédiate. En effet, le calcul de *chaque* matrice de transition locale P^n (i.e. le calcul de la probabilité de mise à jour *et* la mise à jour du site - cf. procédures de mise à jour locales $P.1$, $P.2$ et $P.5$), bien qu'il puisse être effectué localement, est dépendante de la réalisation particulière du champ à l'étape $n-1$. Considérons alors deux sites voisins autorisés à évoluer simultanément ; chacun calculera "sa" force locale à partir d'un état du voisin qui pourra avoir changé à l'issue du calcul, et donc se retrouver incohérent avec la décision d'évolution adoptée. Il en résulte des comportements aberrants, comme par exemple des états oscillants.

La parallélisation est cependant possible en se restreignant à des domaines *non connexes* du champ d'étiquettes. Pour exploiter la localité du calcul sans compromettre les bonnes propriétés de convergence, on peut procéder de la façon suivante : on sépare les sites de la grille S en N_c domaines ou *couleurs* de telle sorte que deux sites de couleur différente ne soient pas en interaction par rapport au voisinage du champ de Markov sous-jacent (i.e. n'appartiennent pas à une même clique)²⁴. On notera alors que les probabilités de mise à jour associées à deux sites quelconques de même couleur sont *statistiquement indépendantes* (pour une configuration d'étiquettes fixe pour les sites de couleur différente). Ce qui veut dire que l'ordre de mise à jour à l'intérieur d'un même domaine de couleurs n'est pas important : en fait tous les sites d'une même couleur peuvent *matériellement* être réactualisés au même instant.

²⁴ Le nombre minimum de couleurs nécessaires pour réaliser cette genre de partition est appelé *nombre chromatique* du modèle de Markov.

Reprenons l'expression de la matrice de transition globale pour la mise à jour séquentielle périodique des sites ; en faisant un tri par couleur des matrices de transition locales (permutation σ dans l'expression ci-dessous), on aboutit à une matrice de transition globale de la forme :

$$P = \prod_{n=0}^{N-1} P^{\sigma(n)} = \prod_{c=1}^{N_c} P_c^1 \dots P_c^{n_c} = \prod_{c=1}^{N_c} P_c^{n_c},$$

où n_c est le nombre de sites appartenant au domaine de couleur c , et P^c est la matrice de transition "chromatique" correspondante. La possibilité de paralléliser la mise à jour des sites de même couleur provient du fait que la matrice chromatique peut être construite indépendamment des valeurs du champ dans le produit.

La *fig.II.7* montre quelques exemples de voisinage de Markov et le nombre chromatique qui leur est associé (le degré de parallélisation de la procédure de mise à jour du champ d'étiquettes est inversement proportionnel au nombre de couleurs).

Condition de stationnarité. Cependant, [Marro85a] montre que la mise à jour parallèle des sites sur chaque domaine de couleur rompt la condition de bilan détaillée (P^c ne respecte pas cette condition) et cela quelle que soit la méthode de mise à jour employée - algorithme de Metropolis, du Thermostat, ou échantillonneur de Gibbs. Heureusement, la distribution de Gibbs est "naturellement" stationnaire pour la chaîne de Markov engendrée par l'échantillonneur de Gibbs (*cf.* §2.2.3).

En conclusion, nous pouvons envisager une parallélisation massive de l'algorithme de relaxation - sur chaque domaine de couleur - à condition d'utiliser l'échantillonneur de Gibbs (car dans ce cas, la stationnarité ne s'appuie pas sur la condition de bilan détaillé). Comme remarqué plus haut, l'échantillonneur de Gibbs se confond avec celui du Thermostat pour un champ à valeurs binaires.

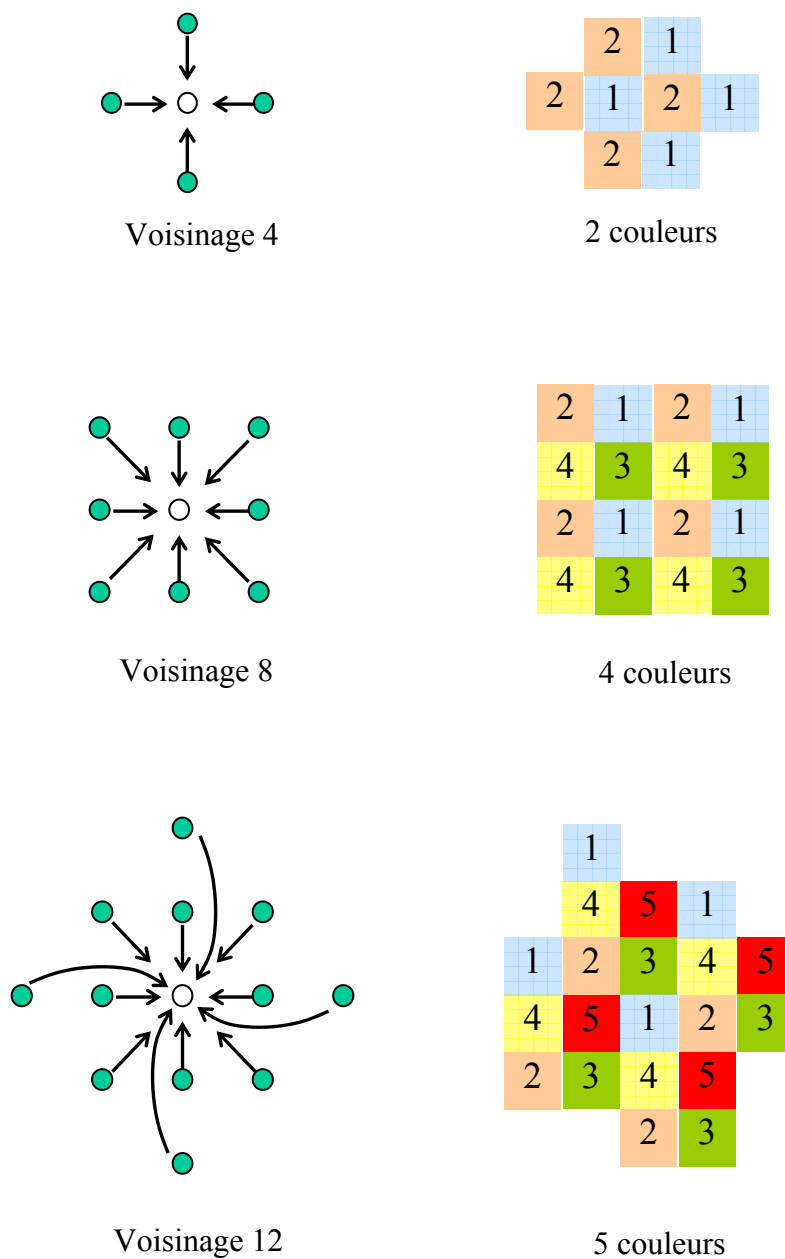


Fig.II.6 : Relation entre voisinage et coloriage permettant de traiter la mise à jour de façon parallèle sur chaque domaine de couleur. L'accélération du temps de calcul par rapport à l'algorithme séquentiel est égale au nombre de sites N de la grille sur le nombre de couleurs N_c dans laquelle elle est partagée.

2.2.6 Conclusion

Tout d'abord il est intéressant de remarquer que les méthodes d'échantillonnage constituent à elles seules un outil permettant d'ajuster les paramètres d'un modèle particulier en traitement d'images. En effet, les techniques présentées dans ce paragraphe permettent d'appréhender de façon "expérimentale" les propriétés statistiques globales émergeant d'un champ de Markov dont on aurait spécifié de façon arbitraire les potentiels locaux des cliques (en générant des échantillons du champ sur lesquels on peut tester divers estimateurs bayésiens, *cf.* Chap.I,§4.2).

Néanmoins, et comme il a été expliqué brièvement au §2.1.2, l'intérêt fondamental des techniques d'échantillonnage de Monte Carlo est que, utilisées conjointement avec une *procédure de refroidissement* (i.e. une loi adéquate de décroissance de la température) celles-ci vont permettre d'approcher la configuration d'étiquettes minimisant une fonction de coût donnée. C'est ce que l'on verra avec un peu plus de détail au paragraphe suivant.

2.3 La procédure de refroidissement ou *Recuit Simulé*

Les méthodes de mise à l'équilibre thermodynamique décrites précédemment peuvent être opérées à une température T quelconque. Il serait tentant de choisir directement une température proche de zéro pour favoriser d'un seul coup les modes fondamentaux de l'énergie. Malheureusement, on montre [Geman86] que le temps de calcul à l'approche de l'équilibre croît exponentiellement avec $1/T$ (voir *fig.II.5*).

L'algorithme de recuit simulé, en faisant décroître la température de manière *contrôlée*, est chargé de contourner cet inconvénient. La chaîne de Markov est tout d'abord rapidement amenée à l'équilibre thermodynamique à haute température ; puis, à chaque itération (i.e. mise à jour complète du champ d'étiquettes), la température est diminuée, et la chaîne est maintenue dans un état *proche* d'équilibre par l'exécution plus ou moins longue (mais jamais infinie!) d'une procédure d'échantillonnage. Le principe du recuit est que à haute température le paysage énergétique est rapidement exploré et le système sort aisément des minima locaux ; puis l'exploration se fait de moins en moins rapide mais le système rôde déjà *plus probablement* autour du minimum global (ou au moins d'un minimum global, s'il y en a plusieurs). Le fait que la température ne soit jamais nulle implique que si l'on attend *suffisamment longtemps*, il existe une probabilité non nulle que le système sorte de n'importe quel minima local, aussi profond soit-il. Toutefois ce temps croît de façon exponentielle avec $1/T$, si bien qu'à basse température l'algorithme se comporte de façon de plus en plus déterministe et seuls les changements *diminuant* l'énergie seront acceptés.

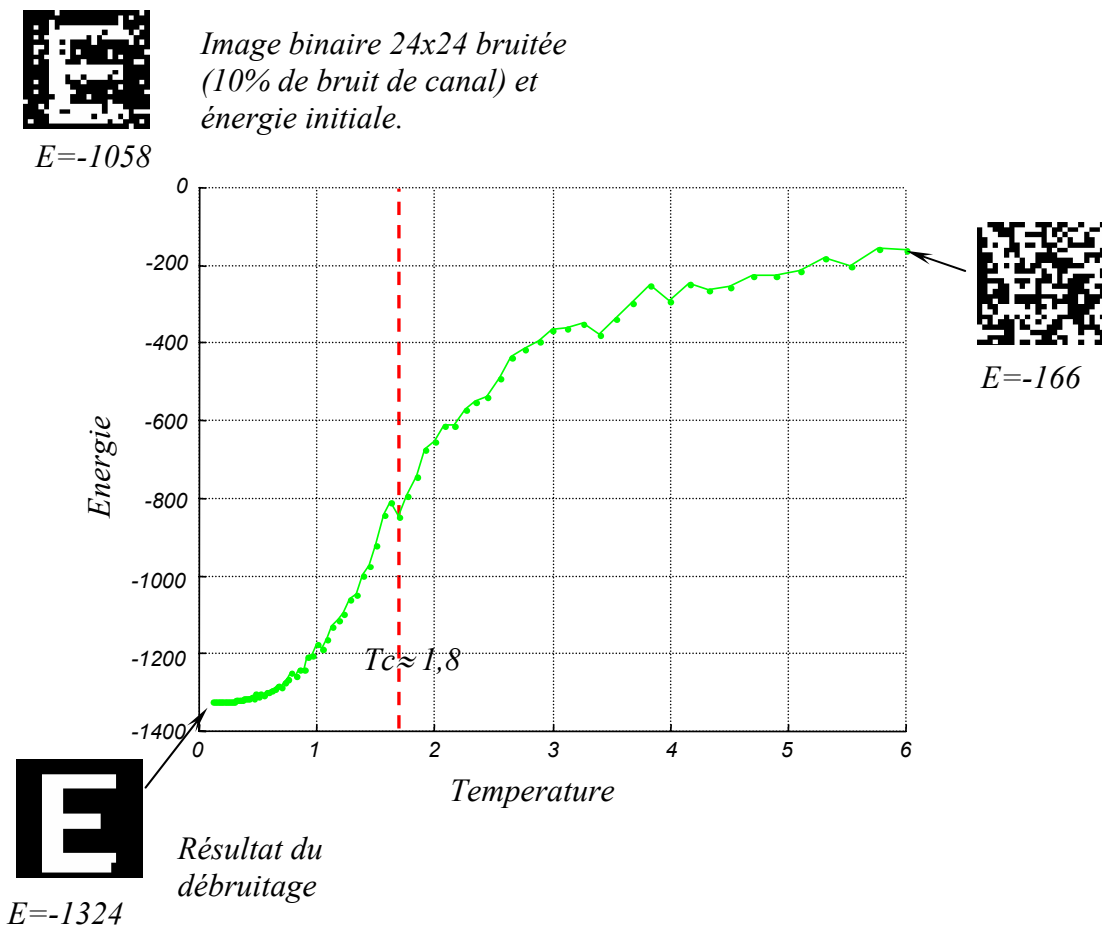


Fig.II.7 : Energie en fonction de la température pendant le recuit simulé. En haut à gauche, l'image originale à débruiter ; en haut à droite, le champ binaire à haute température ($T = 6$) et énergie correspondante ; en bas à gauche, le résultat du recuit et le minimum de l'énergie atteint (température finale $T= 0,1$).

On distingue deux classes différentes d'algorithmes de relaxation correspondant à des schémas de descente en température *continus* ou *par paliers*.

2.3.1. Recuit continu.

Dans ce genre d'algorithmes, la température est abaissée entre deux itérations (mises à jour) consécutives. La chaîne de Markov qui en résulte est inhomogène. Le système n'est jamais totalement à l'équilibre thermodynamique ; cependant, il est démontré formellement [Geman84] que si la température tend vers zéro et que à chaque itération n on a :

$$T_k \geq \frac{\alpha}{\log(n)}, \text{ où } \alpha = \text{card}(\Omega_E) \cdot \left\{ \max_{e \in \Omega_E} [U(e)] - \min_{e \in \Omega_E} [U(e)] \right\},$$

alors la configuration converge vers un mode fondamental de l'énergie (il peut en avoir plusieurs). Malheureusement cette décroissance logarithmique reste dans la pratique beaucoup trop lente pour être effectivement respectée²⁵. En pratique on préfère des lois de décroissance exponentielles plus rapides de type $T_{n+1} = r.T_n$, avec $r < 1$ et proche de 1 ; mais le système risque d'être *piégé* dans des minima locaux.

2.3.2 Algorithmes avec descente en température par paliers.

Pour éviter autant que possible ces pièges, une tactique consiste à maintenir la valeur de la température un peu plus longtemps avant de la changer, dans l'espoir que l'équilibre soit *un peu mieux* atteint à la fin de chaque palier de température (voir procédure P.7). La difficulté consiste alors à déterminer la longueur minimale du palier. Par la suite on se référera à la quantité $nscan(T)$, définie comme le nombre de balayages complets (ou *scan*) de l'image effectués pendant toute la durée du palier à température constante T . Il n'est pas nécessaire que $nscan(T)$ soit beaucoup plus grand que le nombre d'itérations nécessaires pour dépasser le régime transitoire de la procédure d'échantillonnage toute seule - là précisément réside l'intérêt du recuit simulé.

2.3.3 Critère d'arrêt : définition heuristique du "recuit sérieux".

Dans la pratique, l'algorithme stochastique doit être stoppé au bout d'un nombre fini d'itérations. Pour simplifier l'algorithme, nous avons fixé le nombre maximal d'itérations par palier *quelle que soit* la température. L'étude rapide faite au §2.2.4 sur le débruitage d'images binaires montre qu'une cinquantaine d'itérations est suffisante pour atteindre l'équilibre sur des images réalistes (256x256), et cela même pour des températures bien au dessous de la température critique. Cependant, en utilisant une procédure de recuit simulé, et si la décroissance du paramètre de température est lente (typiquement $r \approx 0,95$), on peut obtenir des très bons résultats finaux pour $nscan=20$, voire moins.

La procédure de mise à jour peut être arrêtée dès que le nombre total de transitions non nulles (i.e. changements effectifs) effectuées sur le palier courant est inférieur à un seuil prédéterminé. Nous avons opté pour une alternative qui ne nécessite pas de l'évaluation du nombre de changements effectués à chaque itération²⁶ : c'est la température *finale* du recuit qui est fixée une fois pour toutes. La stratégie est sûre à condition de connaître la valeur de la température critique pour l'ensemble de paramètres

²⁵ La probabilité d'obtenir une solution optimale à l'itération n croît très lentement selon :

$$\Pr(e_n \in \Omega_{opt}) \propto 1 - \left(\frac{K}{n}\right)^\beta,$$

où K et β sont des constantes dépendant du paysage énergétique [Catoni92].

²⁶ l'évaluation du nombre total de changements effectués à chaque itération (ainsi que le calcul d'autres observables telles que l'énergie par exemple) n'est évidemment pas *locale* ; dans le cas du prototype de processeur parallèle (cf Chap.III), c'est l'ordinateur hôte qui prend en charge ce genre d'opérations, et cela *après lecture* de la configuration courante sur la matrice SIMD.

du modèle (β_s et β_o) et la topologie de voisinage choisie (4 ou 8 voisins). Nous avons exploré succinctement plusieurs situations possibles en fixant $\beta_s = 1$ et on faisant varier β_o dans des limites raisonnables²⁷. La température critique varie mais ne dépasse jamais $T=10$ ni ne passe au dessous de $T=0,1$. On aboutit ainsi à un ensemble de paramètres pour le recuit simulé, adaptés aussi bien aux imagettes 24x24 (directement traitables par notre prototype optoélectronique) qu'a des images plus réalistes (256x256).

Une procédure de recuit simulé -pour le débruitage d'images binaires avec un voisinage d'ordre 1 ou 2- sera dite *sérieuse* si elle obéit aux conditions suivantes :

- au moins 15 itérations par palier de température ($nscan \geq 15$) ;
- $T_i \geq 10$ et $T_f \leq 0,1$ avec un taux de décroissance exponentiel $r=0,95$, (soit à peu près 90 paliers de température par recuit).

Le recuit sérieux minimal représente alors $n_c = nscan \cdot \frac{\log\left(\frac{T_f}{T_i}\right)}{\log(r)} \approx 1350$ mises à jour parallèles pour *chaque* domaine de couleur ; c'est aussi le nombre de mises à jour du *champ d'étiquettes tout entier* ou *itérations*. Dans le cas d'un voisinage d'ordre 2 et d'un coloriage quaternaire, le nombre total de mises à jour indépendantes s'élève donc à $4n_c \approx 5390$.

Le *recuit sérieux* ainsi défini n'est pas une prescription générale sur le meilleur choix des paramètres pour le recuit simulé (ni en qualité finale du champ d'étiquettes ni en charge de calcul -i.e. nombre optimal d'itérations). Néanmoins, si l'on respecte les conditions énoncés plus haut sur les paramètres du recuit, on peut s'attendre à des résultats acceptables dans un large éventail de situations (taille de l'image, taux de bruit). L'intérêt de la définition est alors de permettre une étude comparative des performances (puissance de calcul) de diverses réalisations expérimentales dédiées au recuit simulé (voir Chap.VI et VII). Pour simplifier, nous allons considérer par la suite qu'un recuit est sérieux s'il comporte au moins **1000 itérations (mises à jour du champ tout entier)**²⁸.

²⁷ pour un bruit de canal variant entre 10% et 40%, le paramètre β_o varie entre 2 et 1/2. Nous avons fixé arbitrairement β_s , mais ce paramètre peut être estimé rigoureusement à partir de l'image originelle non bruitée (cf Chap.I,§5.1.2).

²⁸ Il est intéressant de remarquer que Geman [Geman84] donne un ordre de grandeur du nombre d'itérations (mises à jour complètes du champ) compris entre 500 et 1000 pour divers problèmes bas-niveau. Dans [Prévos94], il est question de 3500 itérations par recuit -70 paliers de température et 50 itérations par palier.

Algorithme de Recuit Simulé Parallèle

(avec décroissance de la température par paliers)

Paramètres du recuit :

- T_i** : température initiale.
- T_f** : température finale
- r** : facteur de décroissance de la température
- nscan** : nombre d'itérations par palier de température.

Début recuit simulé

T ← **T_i**

Tant que **r.T > T_f**, faire :

 Répéter **nscan** fois :

 Pour *c* variant entre 1 et *N_c* (l'ordre des couleurs n'a pas d'importance) :

 Mettre à jour de façon **parallèle** le domaine de couleur *c* par la procédure de mise à jour de Gibbs (procédure P.5). Pour un champ binaire, cela revient à utiliser la dynamique du Thermostat (procédure P.2), consistant à réaliser les opérations suivantes, sur la totalité des sites de couleur *c* :

- Calculer la *force locale* *F(s)* qui "tire" vers l'état *e(s)=1* définie selon :

$$F(s) = -\Delta U_0^1(s) = - \sum_{c \in C / s \in c} [V_c(e(s) = 1) - V_c(e(s) = 0)]$$

(cette quantité est indépendante de l'état courant du site).

- *Accepter* ce changement avec la probabilité (loi sigmoïde) :

$$\Pr[e(s) = 1] = \frac{1}{1 + e^{-\frac{F(s)}{T}}}$$

 Fin mise à jour du champ d'étiquettes entier (une *itération*)

 Fin thermalisation pour le palier de température courant

T ← **r x T** (refroidissement)

Fin procédure de recuit simulé

P.7 : Procédure de Recuit Simulé Parallèle avec décroissance de la température par paliers.

3. Algorithmes déterministes

3.1 Introduction

Bien que théoriquement sous-optimaux, les algorithmes déterministes offrent une alternative aux méthodes stochastiques souvent trop coûteuses en temps de calcul (même pour des algorithmes parallélisés). En première approximation -et à la lumière de ce qui vient d'être expliqué au paragraphe précédent- les algorithmes déterministes sont des techniques d'échantillonnage qui se déroulent à *température nulle* : à chaque itération, la transition se fait de façon déterministe depuis la configuration courante vers une configuration d'énergie *strictement* inférieure (les remontées d'énergie ne sont jamais acceptées). Ces algorithmes partent d'une configuration initiale et convergent vers le premier minimum local rencontré dans le paysage énergétique (*fig.II.8*).

Si la configuration d'étiquettes initiale est proche d'une solution optimale, alors on peut




Fig.II.8 : Paysage énergétique et importance de l'initialisation dans le cas de la relaxation déterministe (pour simplifier la visualisation on a représenté un espace des configurations unidimensionnel).

espérer converger vers ce minimum global ; si ce n'est pas le cas, l'algorithme est irrémédiablement piégé dans un minimum local de l'énergie. D'où la nécessité de choisir avec soin la configuration de départ. Dans le cas des problèmes inverses en traitement d'images, une possibilité consiste à prendre comme configuration initiale l'estimée du maximum de vraisemblance (c'est à dire le champ d'observation lui même).

Parmi les méthodes de relaxation déterministes largement utilisées figurent :

- L'algorithme ICM (pour *Iterated Conditional Modes*) et proposé par [Besag86]. Il consiste à remettre à jour chaque site du champ avec l'étiquette qui minimise le gradient

local de l'énergie. La convergence vers une solution stable est très rapide. L'arrêt de la procédure peut être décidée par un nombre fixe d'itérations, ou lorsque l'on a atteint un équilibre global sur l'ensemble des sites. L'algorithme ICM n'est autre que l'échantillonneur de Gibbs à température nulle²⁹.

- Le recuit par champ moyen ou MFA (pour *Mean Field Annealing*, [Zerubi90]) fait l'hypothèse qu'un système composé d'un grand nombre de variables en interaction peut être vu comme un ensemble de systèmes à une seule variable, pour lesquels les voisins sont gelés dans leur état moyen (en pratique on remplace les étiquettes voisines du site traité par leur état le plus probable calculé pendant la relaxation).
- L'algorithme du GNC (pour *Graduated Non Convexity*), introduit par Blake et Zisserman [Blake87] consiste à construire une famille de fonctions convexes approchant de plus en plus la fonction d'énergie originale à minimiser. La minimisation de la fonction originale à lieu par minimisations successives de chaque fonction convexe (à minimum unique facile à atteindre par l'algorithme du gradient par exemple). Cette technique cherche à pallier l'inconvénient du piègeage dans un minimum local de l'algorithme ICM.
- Une autre approche astucieuse consiste à réduire l'espace de configurations dans un premier abord pour de l'élargir convenablement ensuite au fur et à mesure de la recherche du minimum par relaxation déterministe : on s'assure ainsi d'une bonne configuration initiale à chaque étape de la relaxation. Ces méthodes portent le nom de méthodes de relaxation *multirésolution*, et ont été introduites en traitement d'images par [Terzop86]. L'initialisation est alors en général moins cruciale que dans le cas où l'on s'attaque directement à l'image dans sa résolution maximale.

Il ne faudrait pas oublier enfin les algorithmes qui sont des variantes "plus ou moins déterministes" du recuit simulé. Ainsi par exemple le MMD (*pour Modified Metropolis Dynamic*) qui prône un choix aléatoire du nouvel état selon une loi uniforme, tandis que la règle d'acceptation d'une nouvelle étiquette est déterministe ou le DPA (*pour Deterministic Pseudo Annealing*) qui tente de rendre la fonction à minimiser convexe par changement temporaire du domaine de définition [Zerubi92]; ou encore l'algorithme de recuit simulé proposé dans [Kato92] qui devient déterministe à basse température.

3.2 Stochastique vs déterministe

Les images présentés dans la *fig.I.4* du Chap.I laisseraient supposer que l'algorithme ICM est "meilleur" que le recuit simulé en termes d'optimisation (surtout dans le cas du voisinage 4). Il n'en est rien : on peut montrer que l'énergie du champ d'étiquettes final

²⁹ à un détail près : à température nulle *et pour une force locale nulle*, la procédure de Gibbs se comporte encore de façon stochastique (voir *fig.II.2*). Le paysage énergétique est mieux exploré, car dans les points d'équilibre instable ($F=0$), le site bascule vers l'un ou l'autre des états de façon équiprobable. Nous avons pu vérifier sur quelques exemples que cela améliore (parfois) le résultat de l'optimisation.

est toujours plus basse dans le cas du recuit simulé (voir *fig.II.9*). Si le résultat de l'optimisation par recuit simulé semble s'écarter plus souvent du "bon" résultat que ne le fait l'ICM, c'est en fait parce que le *modèle de débruitage* utilisée est quelque peu prosaïque (il ne s'agit en fait que d'un cas simple permettant d'exemplifier la technique de régularisation bayésienne). La formation de "grumeaux" et la perte des structures plus fines de l'image binaire originale est tout simplement le résultat auquel on doit s'attendre si l'on ignore le "phénomène" des bords dans le modèle *a priori* de l'image (cf. Chap.I,§5.1.2) ; d'autre part, dans le cas de l'ICM, le champ d'étiquettes est initialisé avec l'image observée bruitée : le résultat final de l'optimisation déterministe restera "proche" de celle-ci (minimum local de l'énergie globale), ce qui aura comme effet "positif" de mieux respecter les discontinuités originales.

Bien qu'employé en dehors des conditions théoriques de convergence (recuit par paliers avec décroissance exponentielle de la température) l'algorithme stochastique de recuit simulé donne généralement de bien meilleurs résultats (en termes d'optimisation) que ses homologues déterministes ; en outre, il est très peu sensible au choix de la configuration initiale (pourvu que la température initiale soit élevée - i.e, bien au dessus de la température critique). La charge de calcul est le seul inconvénient, car il faut non seulement mettre à jour le champ de d'étiquettes un bon nombre de fois (quelque 100 fois plus que pour les méthodes déterministes dans l'exemple du débruitage – voir *fig.II.9*), mais encore il faut tirer *aléatoirement* l'état de chaque variable individuelle. Le recuit simulé ne devient donc (très) intéressant qu'à condition que l'on puisse soulever ces deux obstacles majeurs. Nous allons présenter au chapitre suivant un prototype de machine spécialisé capable de le faire.

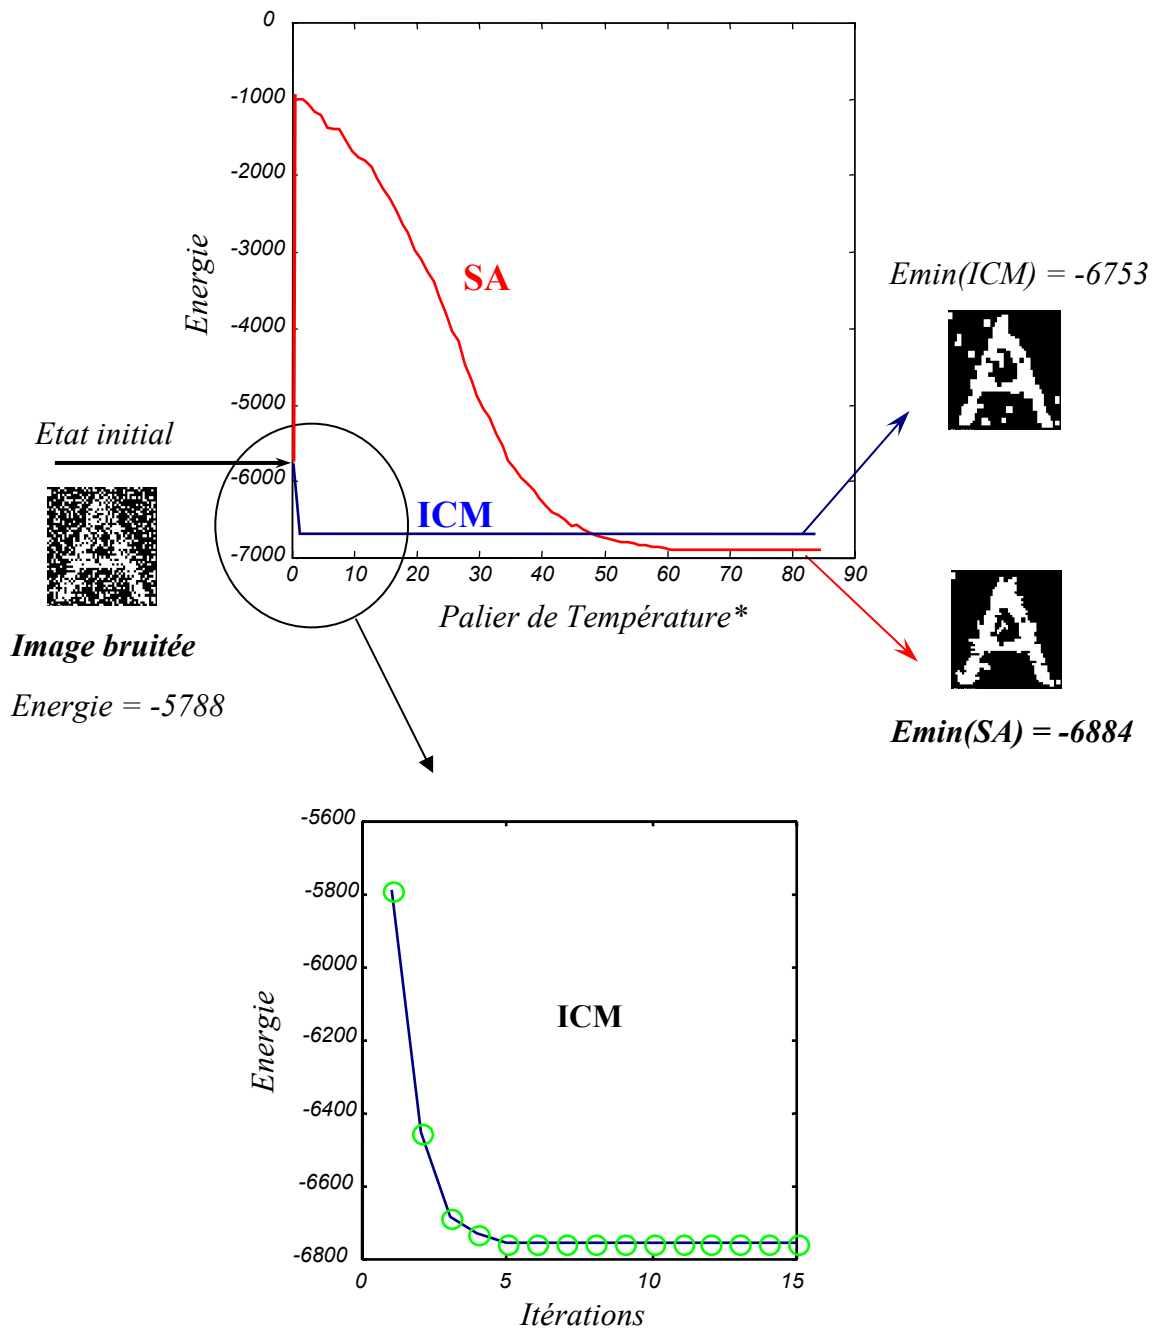


Fig.II.9 : Comparaison entre SA et ICM dans le cas du débruitage d'images binaires sans prise en compte des bords (images synthétiques 40x40).

* Un palier de température correspond à $nscan=10$ itérations du champ entier.

4. Cahier de charges pour un processeur dédié au recuit simulé parallèle.

En résumé, voici le cahier de charges correspondant à une machine SIMD dédié au recuit simulé à cadence vidéo. La machine comporte une matrice de cellules ou processeurs élémentaires (PE) tels que :

1) Chaque PE doit pouvoir stocker une variable d'état binaire (l'étiquette ou *spin*). Il doit être capable aussi de calculer une *force* locale $F(s)$ résultante de la somme des états des PE voisins ;

2) Chaque PE doit être capable d'obéir à la loi probabiliste de mise à jour du *Thermostat* (procédure *P.2*), loi qui est contrôlé *localement* par la force $F(s)$ et *globalement* par le paramètre de température algorithmique T .

3) Chaque cellule doit être capable de réaliser l'opération précédente au minimum à la cadence $f_m=25\text{ kHz}$, nécessaire pour implementer un recuit *sérieux* à cadence vidéo (1000 itérations par recuit).

4) Les différents PEs doivent évoluer de façon quasi-parallèle, en suivant un schéma de *coloriage* préétabli, qui dépend de la topologie du voisinage. Par exemple, le modèle d'Ising aux *quatre* plus proches voisins conduit à un coloriage binaire (en damier). La solution la plus simple consiste à implementer une horloge commune à chaque domaine de couleur (mais d'autres stratégies plus intéressantes peuvent être envisagées permettant de reconfigurer les domaines de couleur, *cf.* Chap.VII,§3 et §4.3).

5. Conclusion

Au Chap.I nous avons étudié quelques problèmes inverses en traitement d'images bas niveau ; nous avons montré que moyennant une modélisation mathématique adéquate du champ de d'étiquettes (i.e. les *primitives* de l'image recherchées), leur résolution passait par la minimisation d'une fonction d'énergie à grand nombre de variables. Cette minimisation est, dans la plupart des cas, un problème d'optimisation *difficile*. Nous avons exposé dans ce chapitre la procédure de **recuit simulé**, méthode **d'optimisation stochastique** générale capable de fournir des solutions très proches d'une solution optimale pour ce genre de problèmes. Le seul inconvénient est la lenteur extrême de convergence quand la procédure est opérée sur un ordinateur séquentiel. En effet, il faut d'une part (a) mettre à jour *une à une* les variables de la fonction d'énergie à minimiser, en calculant à chaque fois le gradient local de l'énergie, nécessaire pour effectuer le tirage aléatoire du nouvel état selon une loi de probabilité bien déterminée (contrôlé globalement par le paramètre de *température*) ; et (b) d'autre part, il faut répéter cette procédure un grand nombre de fois en réduisant très lentement la température du recuit.

Nous avons vu qu'il était possible de **paralléliser** la procédure de recuit simulé à condition d'opérer une sub-division intelligente du champ d'étiquettes. Le **coloriage** du

champ dépend de la structure des interactions entre les variables de la fonction d'énergie à optimiser ; dans le cas particulier de la régularisation d'images par champs de Markov, la parallélisation peut être très efficace (nombre de couleurs réduit) car la portée des interactions entre les pixels du champ est réduite (voisinage d'ordre 1, 2 ou 3).

Il semble évident que les machines séquentielles sont inadaptées pour résoudre efficacement ce genre de problème. Dans le chapitre suivant on discutera de l'implémentation matérielle (optoélectronique) d'une machine parallèle de type SIMD adaptée au cadre précis du traitement d'images bas niveau (dans ce cas, on les appelle parfois rétines artificielles). Quand à la génération de la loi de probabilité de mise à jour, nous allons voir qu'il est également possible de tirer avantage de l'approche optoélectronique, à condition d'utiliser un codage différentiel du champ d'étiquettes.

Chapitre III

Prototype VLSI-CMOS pour le Processeur Parallèle Optoélectronique Stochastique

1. Introduction

Nous allons présenter maintenant un premier prototype de *processeur parallèle optoélectronique stochastique* réalisé en technologie VLSI-CMOS et dédié au problème du *recuit simulé* sur champ binaire *avec* ou *sans* contrainte de rappel aux données (restauration d'images binaires et modèle d'Ising 2D respectivement). Il s'agit d'une puce CMOS à entrées électroniques *et* optiques, (la sortie est réalisée uniquement par voie électronique)³⁰. Un générateur de nombres aléatoires *optique* rend stochastique la dynamique d'évolution de cette puce, baptisée SPIE600 (pour *Speckle Projection for Ising Emulation*, à $24 \times 25 = 600$ cellules ou processeurs élémentaires).

Deux exemples de démonstration sont possibles avec le prototype SPIE600 à interconnexions *électroniques* ; le premier - démontré lors d'une thèse précédente au laboratoire [Prévos95] - rend compte du bon fonctionnement du circuit pour simuler le comportement d'un réseau de spins bidimensionnel (modèle d'Ising 2D) ; le second est à peine plus élaboré, mais déjà plus intéressant : il s'agit de démontrer la capacité du processeur à traiter le problème du *débruitage d'images binaires à cadence vidéo* (sans prise en compte des bords). Dans ce cas, une séquence d'images binaires détériorées par un bruit de canal est présentée à la rétine. Pour chacune d'elles, la relaxation du champ d'étiquettes est réalisée alors avec *contrainte de rappel aux données* ; les interactions -

³⁰ Le circuit pourrait prétendre au nom de *rétine artificielle* étant donné que l'acquisition et le traitement de l'image sont réalisés sur le même circuit. Cependant, l'image (binaire) à traiter doit être codée au préalable au format *double-voie*, c'est pourquoi on préférera le terme de *processeur optoélectronique* ou bien celui de *matrice de pixels intelligents* (cf. Chap.VII).

électroniques - entre différents PEs demeurent dans ce cas exclusivement positives. Le résultat est une image binaire lissée. Il faut cependant un montage optique additionnel pour projeter l'image codée en mode double-voie sur le circuit SPIE600 (celui-ci sera décrit au Chap.V).

2. Rétine artificielle ou machine de Boltzmann ?

La puce SPIE600 n'a pas été conçue dans le but de traiter les deux cas *d'école* décrits en introduction ; en fait, SPIE600 n'est qu'un premier pas permettant de valider certains éléments constitutifs d'une véritable *rétine artificielle stochastique* dédiée à la restauration d'images à niveaux de gris *avec* prise en compte des bords. Ce qui suit est destiné à bien placer le prototype SPIE600 dans le cadre de cette recherche sur les rétines artificielles³¹ ; il en ressortira également que SPIE600 peut être considéré à elle seule comme un prototype optoélectronique simplifié d'une machine de traitement du signal beaucoup plus générale connue sous l'appellation de *machine de Boltzmann*.

2.1 Une rétine artificielle pour la restauration d'images...

Le problème de la restauration d'images dégradées a été exposé en détail au Chap.I,§5. Plusieurs auteurs ont proposé des réalisations VLSI permettant de traiter ce problème. Rappelons que la fonction à minimiser était (*cf.* Chap.I, §5.1.3) :

$$U(e, o, l) = \beta_o \sum_{s \in S} (e(s) - o(s))^2 + \beta_s \left\{ \sum_{s \in S} \sum_{r \in V(s)} (e(s) - e(r))^2 \cdot (1 - l_{sr}) + \Psi_B(l) \right\},$$

où o , e et l sont respectivement le champ d'observation (image à niveaux de gris bruitée), le champ d'étiquettes à niveaux de gris, et enfin le champ binaire des bords. Comme on l'a fait remarquer auparavant, la minimisation de la fonction d'énergie par rapport aux variables d'un champ d'étiquettes à niveaux de gris continus (pour un champ de bords donné) est un problème "facile" que l'on peut résoudre par des algorithmes déterministes efficaces. En effet, la fonction d'énergie est quadratique par rapport aux variables du champ ; en outre il est relativement facile de montrer que celle-ci est convexe par rapport aux variables continues [Blake87] : il suffit alors d'implanter un algorithme de type *descente de gradient*, consistant à faire évoluer le champ suivant la direction opposée au

³¹ Nous allons bien sûr nous limiter à l'étude du problème de la restauration d'images avec prise en considération des discontinuités. Il existe cependant un grand nombre de réalisations expérimentales capables de traiter un large éventail de problèmes de vision bas-niveau (traitements spatiaux et/ou spatio-temporels de l'image), allant depuis des véritables rétines artificielles neuromimétiques jusqu'à des simples éléments de capture "améliorés" (*smart sensors*). Ces réalisations font appel à de très diverses technologies micro-électroniques, combinés parfois sur un même prototype (technologies numérique CMOS, réseaux analogiques, composants optoélectroniques, etc.). Il s'agit d'un domaine dans lequel n'y a pas de "solution définitive" ni d'approche "standard", c'est pourquoi l'exposition des différentes idées et prototypes demanderait un chapitre à part entière. Nous renvoyons le lecteur à l'exposé bref et clair dans [Mhani97].

gradient de l'énergie (pour un champ de bords l fixé). L'équation d'évolution du champ est donné alors par :

$$\forall s \in S, \tau \frac{\partial e(s)}{\partial t} = -\frac{\partial U}{\partial e(s)} = F(s,t)$$

(τ est une constante de temps dépendant du mécanisme de relaxation). Dans notre problème, la *force de rappel* s'écrit :

$$F(s,t) = -\frac{\partial U}{\partial e(s)} = -2\beta_o(e(s) - o(s)) - 4\beta_s \sum_{r \in V(s)} (e(s) - e(r))(1 - l_{sr})$$

Si le paramètre β_o est nul - c'est à dire s'il n'y a pas de rappel aux données - alors l'équation d'évolution est une équation de *diffusion* et le système relaxe jusqu'à ce que tout le champ ait le même niveau de gris ; si le terme de rappel n'est pas nul, le système évolue vers une solution qui approchera mieux l'observation, mais qui sera localement *lissée*³² par le deuxième terme de la force.




Fig.III.1 : réseau de résistances et d'interrupteurs pour la relaxation conjointe du champ à niveaux de gris et du champ de bords binaire (comparer avec la fig.I.6.)

L'idée de résoudre des problèmes variationnels par le biais du calcul analogique (pas nécessairement électrique) fut proposée très tôt [Poggio85], [Hopfie85], [Marro85b], [Koch89], etc.. Sans rentrer dans les détails (voir [Wyatt92], [Prévos92]) le calcul du minimum de la fonction d'énergie peut être réalisé au moyen d'un *réseau de résistances* bidimensionnel suivant la topologie du voisinage du champ de Markov (voir fig.III.1).

³² L'équation de *diffusion* avec "contrainte" (ou équation *Smoluchowski-Kramers* [Diu][Gidas86]) peut être utilisée en optimisation - comme méthode d'échantillonnage à une température donnée - pour des champs à valeurs continus.

Dans la figure, les résistances "horizontales" doivent être proportionnelles au paramètre β_o , les résistances "verticales" au paramètre β_s . Il suffit alors d'injecter en chaque nœud s un courant externe proportionnel à la valeur de la contrainte locale $o(s)$. Dans ces conditions, le système relaxe "naturellement" (en une dizaine de nanosecondes! [Luthon95]) vers la solution escomptée, qui est la distribution des potentiels minimisant la puissance dissipée par le réseau (théorème de la dissipation minimale de Maxwell [Millar51]).

Une architecture prenant en compte le processus de bords (*cf.* Chap.I, §5.1.3) est facilement réalisée par adjonction d'un interrupteur en série sur chaque résistance reliant deux nœuds du réseau (représentés aussi dans la *fig.*III.1). Pour une configuration de bords *donnée*, la relaxation du champ continu est alors réalisée (quasi) instantanément. Inversement, la relaxation du champ de bords - i.e. la configuration "d'interrupteurs" - pour une configuration du champ continu fixé peut être réalisé en utilisant cette fois-ci la technique de recuit simulé (plus complexe à mettre en œuvre - voir plus loin). Cette procédure d'optimisation "mixte" (en partie stochastique et en partie déterministe) fut proposée par [Marro85b] et est connue dans la littérature sous le nom de *mixed-annealing*. Cependant, elle présente l'inconvénient de rompre l'équilibre thermodynamique du champ couplé (le champ continu est traité de façon déterministe, et donc à température *nulle*, alors que le processus de bords est traité de façon stochastique selon une procédure de recuit simulé, à température non nulle). Dans [Prévos95] il est proposé une architecture optoélectronique permettant de relaxer conjointement le champ continu et le champ de bords à *la même température* grâce à l'utilisation d'un algorithme de mixed-annealing modifié, appelé algorithme de *relaxation quasi-statique* ou *RQS* (il "suffit" pour cela de rajouter des sources de courant aléatoires sur les nœuds, pour maintenir la température du champ continu et éviter qu'il ne "refroidisse" trop vite par rapport au champ de bords). La rétine artificielle proposée pour l'implantation du *mixed-annealing* ou du *RQS* se compose donc essentiellement de deux réseaux "superposés" : un réseau de résistances analogique et un réseau d'interrupteurs numériques. C'est dans le cadre de cette recherche que le circuit SPIE600 fut proposé et réalisé - SPIE600 correspond bien sûr au réseau d'interrupteurs ou bords binaires. Dans le prototype, le potentiel d'interaction entre les bords $\Psi_B(l)$ est élémentaire et se résume à l'expression :

$$\Psi_B(l) = \frac{1}{2} \sum_{s' \in S'} \sum_{r' \in V_B(s')} (2.I_{s'} - 1) \cdot (2.I_{r'} - 1),$$

où V_B est un voisinage d'ordre 1 (aux 4 plus proches voisins) invariant par translation sur la grille des bords S' . Pour rendre le prototype plus intéressant (simulation du modèle d'Ising pour le Verre de Spin), SPIE600 a été conçu de sorte à pouvoir prendre en compte des configurations *quelconques* d'interactions *bipolaires* - attractives ou répulsives - entre les bords (la variable binaire codant la présence ou l'absence d'un bord est alors appelée "spin" par analogie avec le modèle du verre de spin - voir §6.1).

2.2 ...une machine de Boltzmann.

Une machine de Boltzmann [Hinton84][Aarts89] est essentiellement un réseau de Hopfield [Hopfield82] - réseau de neurones récurrent - dont l'évolution en chaque site (ou *neurone*) ne se réduit pas à un simple seuillage de la force locale (ou *potentiel neuronal*), mais suit une loi probabiliste de type *sigmoïde* sous le contrôle du paramètre de température T (loi du *Thermostat*, cf. Chap.II, §2.2.2)³³. La dynamique du réseau de neurones est donc *stochastique* ; on a vu au chapitre précédent qu'un tel comportement augmente les chances d'atteindre un minimum absolu de l'énergie (ou *attracteur* du réseau récurrent). En d'autres termes, la machine de Boltzmann (pendant la phase associative du réseau) n'est autre chose que l'implantation matérielle de la procédure de recuit simulé décrite au chapitre précédant pour une fonction d'énergie à variables binaires. Tout comme pour la procédure de recuit simulé, on distingue alors deux sortes de machines de Boltzmann : les machines *séquentielles* et les machines *parallèles* (synchrones ou asynchrones). Les machines de Boltzmann parallèles se prêtent bien à l'implantation dans des machines de type SIMD sur circuit VLSI (appelés parfois *machines-tableaux* ou circuits à *architecture cellulaire*). Dans cette optique, il est clair que SPIE600 est un prototype simple de machine de Boltzmann, pouvant coder uniquement des *poids synaptiques bipolaires* et à interconnexions *locales* [Dupre95b]. Remarquons que - en toute généralité - les poids des interconnexions entre les différents processeurs élémentaires de la machine de Boltzmann (i.e., les *neurones stochastiques*) sont réels et pas nécessairement invariants par "translation" dans le réseau.

L'implantation d'une machine de Boltzmann à interconnexions non invariante par translation est un problème pratique ayant des applications potentielles très intéressantes. En effet, il est facile de montrer que la machine de Boltzmann permet de traiter le problème du *voyageur du commerce* (voir ci-dessous) ; or, celui-ci est un problème NP-complet, ce qui veut dire que tout problème difficile de la classe NP peut être "traduit" (en un temps polynomial) en une instance du problème du voyageur de commerce³⁴. La machine de Boltzmann permet donc de traiter n'importe quel problème appartenant à la

³³ En utilisant la terminologie "neuronale", on dit que la fonction d'activation du neurone est "probabiliste" (le seuil d'activation est une variable aléatoire qui suit la loi sigmoïde à température T).

³⁴ Un problème appartient à la classe P s'il est *soluble* en un temps polynomial par rapport à la taille de données (l'ensemble des distances entre les villes dans l'exemple du voyageur de commerce) ; un problème est dit NP si une solution proposée (i.e. un chemin de parcours des villes dans l'exemple) peut être *reconnue ou rejetée* comme étant une solution du problème en un temps polynomial par rapport aux données. Bien sûr, tous les problèmes P sont NP ; par contre on ne sait pas si l'inverse est vraie : à ce jour on ne sait pas si les problèmes "inextricables" existent véritablement (pour ce genre de problème *il ne peut pas exister* d'algorithme permettant de trouver une solution optimale en un temps polynomial par rapport à la taille des données) ou si les problèmes inextricables rencontrés ne le sont qu'en apparence (on ne *connaît* pas d'algorithme efficaces). C'est un problème ouvert et fondamental. Quoi qu'il en soit, dans la pratique on rencontre souvent des problèmes *difficiles* (sont-ils inextricables?) ; il s'avère en général que les seuls algorithmes connus permettant de trouver à coup sûr la bonne solution du problème prennent un temps qui croît *exponentiellement* par rapport à la taille des données (recherche exhaustive dans l'ensemble des parcours possibles du voyageur de commerce ou dans l'ensemble $\Omega_E=2^N$ des configurations possibles du champ de primitives dans le cas du traitement d'images - cf. Chap.II. §1).

classe NP - à condition de trouver le codage adéquat (c.à.d. les *poids synaptiques* correspondants au problème³⁵).

Exemple de machine de Boltzmann adaptée au problème du voyageur de commerce. Plusieurs fonctions d'énergie ont été proposées pour modéliser le problème du voyageur de commerce ; en voici une due à [Aarts88]:

$$U(e) = \frac{1}{2} \sum_{a,b,k} d_{ab} e_{ak} (e_{b,k+1} + e_{b,k-1}) + \frac{\lambda}{2} \left[\sum_k \left(1 - \sum_a e_{ak} \right)^2 + \sum_a \left(1 - \sum_k e_{ak} \right)^2 \right]$$

où d_{ab} représente la distance entre les "villes" a et b et e_{ak} est une variable binaire qui prend la valeur 1 si la ville a correspond à l'étape k du voyage, (et 0 sinon). Le parcours proposé est ainsi codé sur le "champ d'étiquettes" e . On retrouve dans le premier terme de la somme la distance totale du parcours proposé ; la machine de Boltzmann se doit de minimiser cette distance en tenant compte de deux *contraintes* (termes suivants de la somme) : la première traduit le fait que chaque ville doit apparaître une seule fois dans le parcours ; la deuxième traduit la nécessité (plus abstraite) que chaque étape du voyage se fasse uniquement dans une ville à la fois. Une "bonne" solution du problème peut parfois violer ces contraintes (et devenir alors un parcours "impossible") ; il a été proposé des algorithmes qui respectent ces contraintes de façon *stricte* (c'est la dynamique d'évolution qui change, impliquant par exemple une mise à jour du "champ" par permutation de sites - voir remarque 2 au Chap.II, §2.2.2 et commentaire final dans l'Ann.B, §2).

3. Architectures optoélectroniques pour la machine de Boltzmann.

Plusieurs architectures optoélectroniques ont été proposées pour implanter des réseaux de neurones formels (aussi bien récurrents que propagatifs). Trois éléments doivent être représentés dans l'architecture du prototype, à savoir : le tableau de neurones formels (chaque neurone comporte essentiellement des éléments de transduction optique/électronique, un point mémoire binaire et un comparateur), la topologie d'interconnexion (ou *matrice des connexions*) et les poids correspondant aux interconnexions (ou *matrice des poids synaptiques*). Les prototypes pour lesquels ces éléments sont tous les trois optiques sont plutôt rares ; par contre les réalisations dans lesquelles les interconnexions et les poids synaptiques sont réalisés par des moyens optiques et le tableau de neurones par des moyens électroniques sont bien représentées

³⁵ En restauration d'images, la définition du voisinage de Markov est une façon de définir *explicitement* le "codage" (poids synaptiques correspondants au problème) ; on remarquera toutefois que dans la plupart des cas le "codage" direct en termes de poids synaptiques est impossible : c'est le cas pour presque tous les problèmes de *reconnaissance de formes* par exemple, problèmes pour lesquels on ne connaît qu'un nombre plus ou moins grand de *vecteurs d'apprentissage*. Dans ces cas il est encore possible de "trouver" un codage grâce à des méthodes d'*apprentissage* du réseau (supervisé, non supervisé ou automatique). En fait, c'est là le principal intérêt des réseaux des neurones (appelé parfois capacité de *généralisation* du réseau).

dans la littérature. Il s'opère naturellement une classification des différentes architectures optiques (pour une étude comparative, voir [Duvill96]) :

- architecture optique à *synapses localisées*. Les interconnexions (et les poids associés) sont accessibles de façon indépendante les unes des autres, car elles sont codées dans un modulateur spatial de lumière. L'architecture typique est connue sous le nom de "vecteur×matrice" (on distingue notamment une architecture macro-optique dans laquelle les poids synaptiques sont localisés dans un tableau 2D, et l'architecture plus compacte à microlentilles appelée parfois "matrice×tenseur"). Ces architectures optoélectroniques bénéficient d'une quinzaine d'années d'expérimentation, et s'apparentent essentiellement au dispositif pionnier "vecteur×matrice" de CalTech dans le domaine des réseaux de neurones optoélectroniques [Farhat85].
- architectures optiques à *synapses non-localisées*. Ce type d'architecture est essentiellement représenté par les dispositifs à interconnexions holographiques, pour lesquels on ne peut modifier les poids qu'en recalculant ou en re-enregistrant l'hologramme d'interconnexion. Ces architectures bénéficient de plus d'une trentaine d'années d'expérimentation sur les mémoires associatives holographiques. On distingue notamment les dispositifs utilisant des hologrammes minces (par exemple [Lalann87][Cheval89]) de ceux utilisant des hologrammes en volume (par exemple [Frauel99]).

Dans le cas des réseaux de neurones *récurrents*, cette description peut être complétée par une autre : il est en effet utile de distinguer les systèmes pour lesquels la détection et l'émission des signaux optiques circulant dans la *boucle de rétroaction* optique du réseau récurrent a lieu sur des supports matériels *distincts* (*cf.* Chap.VII, §2.3.2) reliés par un montage optique plus ou moins compact, de ceux pour lesquels la boucle de rétroaction est *monolithique* (la détection et l'émission des signaux optiques est faite sur le même support optoélectronique).

Dans le cas où la boucle de rétroaction n'est pas monolithique, il est probable qu'une partie du traitement (par exemple la conversion des données au format présentable sur le circuit optique, mais aussi les opérations non linéaires réalisées par le neurone formel) soit réalisée par des moyens électroniques ou informatiques (en l'occurrence sur un ordinateur hôte). Le montage optique pour la boucle de rétroaction n'est pas toujours encombrant : citons par exemple la *neuropuce optoélectronique* à synapses localisées de Mitsubishi, (paire de puces émettrice et réceptrice en technologie GaAs, réunies par *flip-chip bonding*) servant uniquement à coder la matrice des poids synaptiques [Ohta90], et la puce développée par AT&T [Rietma89] où les poids synaptiques peuvent être contrôlés optiquement (il s'agit d'une matrice d'électrodes croisées connectées par du silicium amorphe hydrogéné, sensible à la lumière).

Pour finir, remarquons que l'implantation complète d'une machine de Boltzmann sur circuit *électronique* VLSI ne s'est pas faite attendre avec, par exemple, la *neuropuce* de Mitsubishi [Hirai92] comprenant 336 neurones formels binaires *totale*ment interconnectés par des poids multivalués codés sur 5 bits, et capable d'apprentissage et de généralisation. Des applications concrètes ont aussi vu le jour, par exemple le prototype de rétine artificielle bi-puce (puce pour acquisition et codage et neuropuce parallèle réalisant 100Mops) pour la reconnaissance de caractères imprimés de [Masa99] capable de reconnaître 1000 caractères à la seconde. Une éventuelle réalisation optoélectronique doit donc d'ores et déjà relever de sérieux défis.

4. Une machine de Boltzmann simplifiée pour le traitement d'images : le PPOS.

Néanmoins, l'implantation matérielle d'un réseau de neurones sur circuit OE-VLSI à rétroaction optique monolithique devrait conduire à des réalisations très performantes (*cf.* Chap.VII) ; à ce jour, il n'existe pas -à notre connaissance- de véritable prototype de machine de Boltzmann parallèle optoélectronique à *interconnexions reconfigurables* et *totale*ment interconnectée - à synapses localisées ou non - réalisé sur circuit OE-VLSI à entrées et sorties optiques et fonctionnant en rétroaction optique monolithique. Quelques prototypes expérimentaux existent pourtant qui vont dans cette direction. La plupart sont des composants à cristaux liquides sur circuit intégré (prototypes de l'Université de Boulder [Bar95][Mao93]). Dans [Lin93] (équipe de Psaltis à Caltech) est étudiée une matrice optoélectronique de neurones *stochastiques* en substrat GaAs à entrées et sorties optiques (diodes LED et phototransistors), pour laquelle est proposée une architecture d'interconnexion vecteur×matrice ou holographique.

La réalisation de réseaux de neurones formels sur circuit VLSI pourrait bénéficier des nouvelles technologies optoélectroniques très performantes (matrices de VCSEL et MQW en particulier) développées pour la transmission de données entre processeurs ou cartes (*cf.* Chap.VII). Les chapitres V, VI et VII de cette thèse peuvent être vus comme une réflexion sur le sujet, en se rapportant au cas particulier de la machine de Boltzmann appliquée aux problèmes de vision bas niveau. En effet, les problèmes de vision bas niveau qui nous intéressent (débruitage d'images binaires, détection du mouvement) nécessitent un voisinage d'interconnexion *limité* et surtout, *invariant par translation* (*shift-invariant*), c'est pourquoi il est intéressant d'étudier la possibilité d'interconnecter les neurones ou PEs par *voie optique*, l'architecture de choix étant à synapses *non-localisées* (*cf.* Chap.V). Comme on le verra par la suite, on peut également profiter de l'optique pour contrôler l'évolution stochastique du processeur. Nous appellerons ce type particulier de machine de Boltzmann dédié au traitement d'images bas niveau, *processeur parallèle optoélectronique stochastique* (PPOS en abrégé). Au Chap.VII on étudiera des circuits OE-VLSI à entrées et *sorties* optiques permettant de réaliser une boucle de rétroaction optique *monolithique*.

En résumé, la puce SPIE600 -conçue initialement pour intégrer une véritable rétine artificielle analogique-digitale- constitue donc un premier prototype de PPOS à interconnexions électroniques (le bouclage est monolithique, mais pas optique -les entrées optiques de SPIE600 servent uniquement au contrôle de l'évolution stochastique et à l'introduction de l'information à traiter). Dans le chapitre V nous allons démontrer la possibilité d'étendre le système de voisinage de SPIE600 grâce à des interconnexions optiques (montage de convolution 4-f comportant un SLM et un hologramme de Damman : la rétroaction n'est plus *monolithique*).

5. Présentation du processeur SPIE600

La puce SPIE600 (CMOS 1 μ m), conçue dans le cadre de la thèse de A.Dupret [Dupre95a], est une matrice de processeurs élémentaires (PEs) à mémoire binaire reliés entre eux par des interconnexions électriques aux 4 plus proches voisins (voisinage d'ordre 1). Elle comporte 600 PE, dont 576 fonctionnels rangés sur une matrice carrée 24x24 (la dernière ligne est une ligne de calibration, permettant de tester indépendamment certains éléments de la cellule élémentaire). Chacune des rangées de la matrice comporte un registre à décalage qui permet de lire et charger de proche en proche la configuration de "spins" (i.e. le champ d'étiquettes³⁶) ainsi que les poids des interactions sur la puce (*fig.II.1*). Les différents PEs évoluent de façon quasi-*parallèle*, pour ne pas rompre l'équilibre thermodynamique lors de la relaxation du champ de spins (*cf.* Chap.II, §2.2.5). Deux horloges indépendantes fournissent le signal de mise à jour pour les sites noirs et blancs respectivement (coloriage binaire).

Le circuit électronique ne comporte pas de générateur (pseudo) aléatoire numérique pour la mise à jour stochastique du champ d'étiquettes (en suivant la loi sigmoïde du Thermostat, *cf.* Chap.II, §2.2.2). L'état (binaire) de chaque PE évolue de façon *déterministe* en fonction du voisinage, par simple *seuillage* de la force locale. Celle-ci est calculé électroniquement, grâce à une simple addition analogique des courants électriques. Par contre, le seuil est déterminé *optiquement*, grâce à une paire de photodétecteurs (voir *fig.III.2*).

Tout l'intérêt du circuit SPIE600 réside dans le fait que son comportement peut être rendu facilement *stochastique* : en effet, puisque chaque PE possède un circuit analogique de détection différentielle pour la détermination du seuil, le fonctionnement de chaque processeur élémentaire peut être piloté par un signal aléatoire optique aux propriétés statistiques contrôlées provenant d'un générateur de nombres aléatoires optique basé sur le phénomène de speckle laser [Lalan95a]. SPIE600 est donc un

³⁶ L'étiquette *binaire* peut prendre deux valeurs au site s : $e(s) \in \{0,1\}$. La configuration de spins correspondant au champ d'étiquettes est *bipolaire* (± 1) : la valeur du spin au site s est donné alors par $(2.e(s)-1) \in \{-1,1\}$.

processeur *parallèle* à la fois *numérique* (points mémoire binaires) et *analogique* (détermination du seuil et calcul de la force locale).

5.1 Architecture électronique globale

Comme dit plus haut, SPIE600 est capable de représenter des interactions locales aussi bien attractives que *répulsives* entre PEs, c'est pourquoi il est possible de simuler le comportement du Verre de Spin (cf §6.1). Pour cela, deux points mémoire supplémentaires codant les interactions bipolaires (± 1) ont été ajoutés par cellule (notation : J_r avec $r \in V(s) = \{r_N, r_S, r_E, r_O\}$). La *fig.III.2* ci-dessous représente l'architecture électronique de l'ensemble de la matrice ainsi que celle d'un PE individuel. La préparation des interactions avant toute opération ainsi que la récupération du résultat est faite en série sur les colonnes au moyen d'un bus parallèle 24 bits sur les lignes (boucle de registres à décalage).

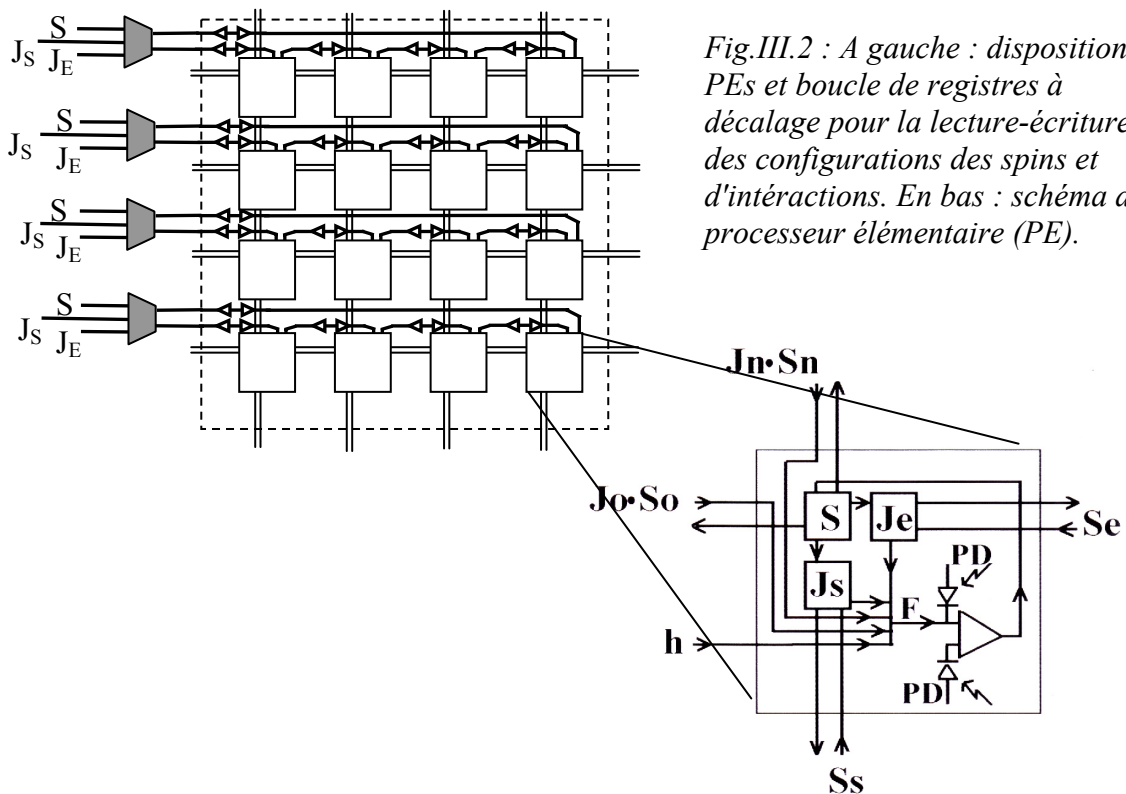


Fig.III.2 : A gauche : disposition des PEs et boucle de registres à décalage pour la lecture-écriture des configurations des spins et d'interactions. En bas : schéma du processeur élémentaire (PE).

5.2 Le processeur élémentaire.

Chaque cellule ou PE comporte 112 transistors et occupe une surface de $215 \times 216 \mu\text{m}^2$. Le calcul de la force locale $F(s)$ est *analogique* (sommateur de courant) et s'effectue par addition de quatre courants bipolaires (et de valeur absolue constante) $\pm I_S$ dont le signe est déterminé par le produit des "constantes de couplage" J_N, J_S, J_E, J_O (2 points mémoires binaires par PE, voir *fig.III.2*) avec la valeur des spins voisins correspondants (un point mémoire binaire par PE). A cette quantité vient s'ajouter un courant I_h

correspondant à un champ extérieur uniforme h . Plus exactement, le *courant* correspondant à la force locale au site s est donné par :

$$I_F(s) = I_S \sum_{r \in V(s)} J_{rs} (2e(r) - 1) + I_h$$

Ce courant est effectivement mesurable sur un unique site de test, (sortie SPIN_OUT de SPIE600). Le contrôle de la valeur des courants I_h et I_S est fait directement, grâce aux plots de la puce SPIE600 h_pol et f_pol respectivement (de résistance caractéristique de l'ordre du $M\Omega$). Les courants sont de l'ordre du μA (les *tensions* de commande sont alors de l'ordre de la centaine de mV). Une paire de photodétecteurs (PD dans la figure) - plus précisément des phototransistors - permet la conversion des éclaircissements aléatoires optiques en un photocourant aléatoire différentiel "de seuillage" I_d (voir paragraphe suivant). Enfin, un comparateur (représenté par un triangle dans la figure) permet la mise à jour de l'état du PE par comparaison du courant I_F avec le photocourant différentiel I_d . Pour plus de détails quand aux cellules analogiques et numériques, voir [Dupre95a].

5.3 Le générateur de nombres aléatoires optique (RNG)

5.3.1 Introduction.

La génération de nombres aléatoires statistiquement indépendants et ayant une loi de probabilité donnée est, comme on l'a vu au Chap.II, un élément clé pour l'implantation de la procédure d'échantillonnage du recuit simulé. Par ailleurs, l'utilisation d'un grand nombre de processeurs élémentaires travaillant en parallèle exige la génération d'une quantité considérable de nombres aléatoires indépendants dans le temps *et* dans l'espace. La génération de telles variables aléatoires indépendantes par des moyens purement électroniques est possible [Belhai90], mais soulève le problème de l'encombrement de la surface de la puce et, de ce fait, limite la densité de processeurs élémentaires et/ou la qualité des séries temporelles pseudo-aléatoires -si l'on se limite à l'utilisation des fonctions de l'électronique numériques.

La génération *optique* de nombres aléatoires offre plusieurs avantages : (a) tout d'abord les quantités aléatoires proviennent d'un processus stochastique réel (bruit de photon [Morris86] ou champ de speckle [Marron86] par exemple) ; (b) le signal aléatoire est ensuite véhiculé en espace libre et distribué *en parallèle* sur tous les processeurs de la matrice ; (c) l'interface optoélectronique au sein de chaque PE se limite à des éléments de photodétection et mise en forme du signal (amplification et/ou seuillage) ; enfin, les paramètres statistiques des variables aléatoires dépendent de l'éclaircissement et sont modifiables instantanément sur l'ensemble de la matrice.

Les points (b) et (c) peuvent constituer aussi des désavantages : les défauts du système d'imagerie optique et la dispersion (plus ou moins inévitable) des caractéristiques des photodétecteurs induisent des variations locales des propriétés statistiques des nombres aléatoires sur chaque site (voir Chap.VI, §1.3 et fig.VI.8). Néanmoins, l'approche a été

validée dans des travaux précédents dans notre laboratoire dans le cas de la génération massive de courants aléatoires de nature gaussienne [Lalan95a] et sigmoïde [Prémon94], ayant de très bonnes qualités spatiales et temporelles.

5.3.2 Génération de la loi du Thermostat à partir du speckle

L'algorithme de recuit simulé parallèle utilise, pour la mise en équilibre du champ aléatoire à chaque palier de température, la procédure d'échantillonnage de Gibbs. Celle-ci est équivalente dans le cas de variables binaires à la loi du *Thermostat* (cf. Chap.II, §2.2.2) ; la loi d'évolution que chaque PE doit être en mesure de suivre pour la mise à jour de son étiquette est donc la probabilité sigmoïde (Chap.II, §2.2.2, fig.II.1.2) :

$$\Pr[e(s) = 1] = \frac{1}{1 + e^{-\frac{F(s)}{T}}}$$

Cette probabilité de transition dépend du paramètre de contrôle T (appelé température) ainsi que de la différence d'énergie ou force locale $F(s) = -\Delta U(s)$ entre l'état du champ courant E avec localement $e(s)=1$ et l'état courant avec localement $e(s)=0$. Le processeur élémentaire doit générer une sortie (binaire dans le cas qui nous intéresse) selon cette distribution. L'élément de base pour réaliser l'échantillonneur de Gibbs est schématisé ci-dessous (fig.III.3) : il s'agit de ce que l'on pourrait l'appeler un *comparateur stochastique*, le comparateur classique étant un cas particulier quand la température est nulle. Nous allons montrer par la suite - points a), b) et c) - comment on peut s'y prendre pour transformer un comparateur classique en un comparateur stochastique grâce à l'introduction d'un courant aléatoire photoinduit, ayant les bonnes propriétés statistiques.




Fig.III.3 : Comparateur "stochastique"(contrôlé optiquement) permettant la mise à jour des sites selon la loi du Thermostat à température T .

a) Statistiques du speckle.

Le *speckle* est un phénomène d'interférences découlant de l'introduction de déphasages aléatoires dans un front d'onde cohérent [Goodman85]. La réflexion d'un faisceau cohérent sur une surface rugueuse ou sa traversée par un milieu présentant des granularités dont la dimension caractéristique est de l'ordre de la longueur d'onde,

produisent une figure de speckle caractéristique contenant un grand nombre d'éclairement aléatoires. La distribution de probabilité de l'éclairement I reçue par un photocapteur placé dans le champ de speckle est en première approximation donné par la loi de distribution gamma [Dainty84] :

$$\Pr_M(I = i) = \frac{1}{\Gamma(M)} \left(\frac{M}{\langle I \rangle} \right)^M i^{M-1} \cdot \exp \left[-\frac{M}{\langle I \rangle} i \right], \quad (i \geq 0).$$

Dans cette expression, le paramètre M désigne le nombre de degrés de liberté associé au champ d'intensité observé et il est donné par le carré du rapport signal sur bruit du champ

de speckle : $M = \left(\frac{\langle I \rangle}{\sigma_I} \right)^2$, où $\langle I \rangle$ dénote l'intensité moyenne et σ_I l'écart type de

l'éclairement. En accord avec le théorème de la limite centrale, la densité de probabilité gamma de speckle tend vers une distribution gaussienne lorsque le nombre de degrés de liberté M tend vers l'infini ; le paramètre M peut aussi être interprété comme le nombre moyen de grains de speckle incidents sur le photorécepteur (voire plus loin).

b) Détection différentielle du speckle

L'éclairement aléatoire est converti en photocourant aléatoire grâce à des phototransistors en technologie CMOS sur chaque processeur élémentaire de la rétine (voir *fig.III.4* ci-dessous). A partir d'une détection différentielle sur deux photodétecteurs (suffisamment éloignés pour que les statistiques de speckle soient indépendantes) il est possible d'obtenir une distribution de photocourants presque gaussienne et *centrée* de très bonne qualité.




Fig.III.4 : Comparateur classique à deux entrées et détection différentielle de speckle. Le courant photoinduit détermine le seuil du comparateur.

En effet, si l'on suppose que la réponse des photodétecteurs est linéaire et que les éclairements sont indépendants, la densité de probabilité $\Pr(I_d)$ associé à la différence I_d des photocourants induits I_1 et I_2 est donné par l'autocorrélation de la loi de probabilité gamma de speckle :

$$\Pr(I_d = i) = \Pr(I_1 = i) * \Pr(I_2 = i) = \int_{-\infty}^{+\infty} \Pr(I_1 = x) \cdot \Pr(I_1 = x - i) dx$$

Cette intégrale peut être évaluée analytiquement ; il s'ensuit [Lalan95a] que $\Pr(I_d)$ est quasiment gaussienne même pour des faibles valeurs de M (écart maximal toujours

inférieur à 1% pour $M < 5$), ce qui n'était pas le cas pour une détection directe de l'intensité de speckle. De plus, la loi est automatiquement centrée, quel que soit le site considéré ; enfin, l'écart type de la distribution gaussienne ajustée est approximativement donné par :

$$\sigma_{I_d} = \sqrt{2}\sigma_I \approx \sqrt{\frac{2}{M}}\langle I \rangle$$

c) Seuillage de la gaussienne et loi du Thermostat.

La probabilité que la sortie du comparateur de la *fig.III.4* soit active est donnée par la probabilité que le courant $I_F(s)$ représentant la force locale $F(s)$ soit inférieur au photocourant différentiel I_d ; autrement dit, la probabilité en question est donnée par la fonction de répartition de la loi différentielle (quasiment gaussienne) :

$$\Pr(e(s) = 1) = \Pr(I_d < I_F(s)) = \int_{-\infty}^{I_F(s)} \Pr(I_d = i) di \approx \text{Erf}_{\sigma_{I_d}} [I_F(s)]$$

Or, on peut montrer que la fonction de répartition d'une gaussienne (fonction noté *Erf* ci-dessus) ne diffère pas plus de 1% de la loi sigmoïde recherchée [Lalann90] :

$$\text{Erf}_{\sigma_{I_d}} [I_F(s)] \approx \frac{1}{1 + \exp\left[-\frac{I_F(s)}{T}\right]}$$

Pour des valeurs élevées de M , la température T de la loi sigmoïde peut être trouvée analytiquement en posant que sa dérivée à l'origine soit égale à la pente d'une loi normale ; on a alors :

$$T = \sqrt{\frac{\pi}{4}}\sigma_{I_d} = \sqrt{\frac{\pi}{4M}}\langle I \rangle$$

Plus généralement, la dépendance de la température avec l'écart type σ_{I_d} de la gaussienne peut être estimée en ajustant la loi de probabilité sigmoïde avec la loi de répartition $\Pr(I_d < i)$; on montre alors que ces quantités sont proportionnelles et que la constante de proportionnalité α dépend du paramètre M et tend vers 0,94 quand M tend vers l'infini [Prémon99] :

$$T = \alpha(M) \cdot \sqrt{\frac{\pi}{4M}}\langle I \rangle, \text{ avec } \lim_{M \rightarrow \infty} \alpha(M) \approx 0,94$$

On retiendra que la température algorithmique est proportionnelle à l'intensité de l'éclairage, et que le facteur de proportionnalité dépend du nombre de degrés de liberté M du speckle.

5.3.3 Montage générateur de speckle : paramètres $\langle I \rangle$ et M .

Le montage expérimental pour générer le champ de speckle est schématisé dans la fig.III.5. Le speckle est produit par l'interférence aléatoire des différents modes de propagation dans une fibre optique multimodale. La diode laser utilisée est une SDL-5412 (Spectra-Physics) de 100mW de puissance maximale, émettant à 847 nm. L'ordinateur hôte contrôle la puissance de la diode par le biais de la tension de commande V_d . Pour assurer l'excitation d'un grand nombre de modes de propagation, un diffuseur est placé devant la face d'entrée de la fibre. La face de sortie de la fibre est imagée ensuite sur la surface du circuit. Le générateur de speckle délivre une puissance optique maximale de $10\text{mW}/\text{cm}^2$ (assurant une commutation *totale*ment aléatoire des PE




Fig.III.5 : Génération de la loi sigmoïde à partir de la détection différentielle de speckle. Le photocourant aléatoire produit par le speckle rend variable le seuil du comparateur "classique" : celui-ci réalise alors une très bonne approximation du comparateur "stochastique" de la fig.III.3.

à la fréquence maximale de 250kHz). La complexité du montage optique est comparable à celle d'un lecteur de disques compacts.

Paramètre $\langle I \rangle$: Une uniformité allant jusqu'à $\Delta I / \langle I \rangle = 6\%$ (ΔI représente les variations crête à crête de l'intensité moyenne) à la sortie de la fibre a pu être démontrée sur un tel montage [Lalan95b]. Dans le montage plus complexe qui sera étudié au Chap.V, et pour des raisons d'encombrement, le speckle n'est pas incident à angle droit sur la puce ; ceci induit un gradient spatial d'intensité qui se traduit par un gradient spatial de température algorithmique sur la puce (cf. Chap.IV, §1.3.2).

Paramètre M . Le nombre de degrés de liberté M (défini comme le carré du rapport signal sur bruit) est donné par le nombre de grains de speckle indépendants incidents sur chaque photodétecteur pendant la durée de détection. On a plus précisément $M = 2.M_s.M_t$, où M_s est le nombre maximal de grains de speckle présents simultanément sur la surface du détecteur, et M_t indique le nombre de champs de speckle

indépendants imagés sur le circuit pendant la durée de photodétection - le facteur 2 rend compte des deux polarisations perpendiculaires sortant de la fibre.

Les caractéristiques géométriques du montage optique imposent $M_S \approx 5$ (soit 5 grains de speckle sur la surface - $35 \mu\text{m}^2$ - du photodétecteur) ; l'indépendance spatiale des échantillons de speckle est assurée puisque la distance entre les fenêtres de détection ($128 \mu\text{m}$) reste très supérieure au diamètre du grain de speckle.

Par ailleurs, la décorrélation *temporelle* des figures de speckle est assurée par la vitesse de rotation du diffuseur [Jourda93]. Le dispositif de génération de speckle utilisée peut produire jusqu'à 100.000 champs de speckle indépendants par seconde [Lalan95a]. Cependant, la corrélation temporelle des *courants photoinduits* sur chaque site est conditionnée par la bande passante des phototransistors CMOS : le taux de génération de nombres aléatoires non *corrélés temporellement* est donc borné supérieurement - et cela indépendamment du montage optique (vitesse de rotation du diffuseur). Si l'on modélise le photo-capteur comme un filtre passe-bas de premier ordre de fréquence de coupure $f_c = 1/\tau$, alors le coefficient de corrélation entre deux échantillons aléatoires pris à un intervalle de temps Δt est égal à $\exp(-\Delta t/\tau)$ [Dupret95a]. Si l'on veut - par site - un taux de génération de nombres aléatoires temporellement indépendants (corrélation $< 1\%$) supérieur à 50 kHz ($\Delta t = 20 \mu\text{s}$) nécessaire pour pouvoir réaliser 25 recuits sérieux par seconde (1000 itérations) avec un système de voisinage d'ordre 1 (coloriage binaire), alors la bande passante du circuit de photodétection doit être supérieure à 230 kHz. Les phototransistors associés à la détection différentielle ont une bande passante de l'ordre de 250kHz pour un éclairage de $10 \text{mW}/\text{cm}^2$ (photocourant de l'ordre de $1 \mu\text{A}$). Dans ces conditions, et si l'on fait travailler le circuit à la cadence de 230 kHz, on aura $M_T \approx 1$. Finalement, le nombre de degrés de liberté est de l'ordre de $M \approx 10$, et la détection différentielle seuillée de speckle donnera une bonne approximation de la loi de probabilité sigmoïde de mise à jour (voir Chap. VI, fig. IV.6).

5.4 Conclusion.

Le tableau suivant (*tab.III.1*) résume les principales caractéristiques de SPIE600. Il sera utile pour établir une comparaison des performances avec d'autres prototypes de processeurs optoélectroniques (voir Chap.VII, §2.4.2).

Caractéristiques globales de SPIE600	
Nombre de PEs fonctionnels	24x24 = 576
Surface totale de la puce	≈5x5 mm ²
Fréquence d'horloge maximale	250 kHz (*)
Puissance électrique consommée	10mW
Caractéristiques d'un PE	
Surface du PE	215x216 μm ²
Transistors par PE	112
Entrées optiques par PE	2
Sorties optiques par PE	0
Détection différentielle (phototransistors MOS cascodés)	
Taille fenêtre optique	35x35 μm ²
Séparation des fenêtres	128 μm (**)
Sensibilité	0,1-0,2 A/W
Gain	≈40
Bande passante	250 kHz (*)

Tab.III.1 : Caractéristiques optoélectroniques du prototype SPIE600.

(*) pour un photocourant induit par une source de speckle de 10mW/cm² sur la surface de la puce (de l'ordre du μA). (**) >50μm pour décorrelation spatiale [Dupret95a].

On remarquera enfin que n'importe quel élément de photodétection différentielle est susceptible d'être employé pour générer des lois sigmoïdes à partir du générateur de speckle. Dans [Prémon99] il est question de photothyristors optiques, composants expérimentaux qui ont donné lieu à des essais préliminaires ; au Chap.VII nous allons envisager la réalisation d'une matrice de PE stochastiques utilisant des diodes p-i-n à puits quantiques multiples qui pourraient être un prolongement au présent travail si l'état de la technologie le permet.

6. Le recuit simulé sur SPIE600.

La validation expérimentale de SPIE600 a fait l'objet d'un travail de thèse au laboratoire [Prévos95]. Nous allons illustrer ici le fonctionnement du circuit SPIE600 tel qu'il peut marcher sans autre montage optique que le générateur de speckle (correspondant à l'expérience du *verre de spin*). Une caractérisation plus approfondie du prototype sera faite au Chap.VI, qui, elle, prendra en compte les particularités d'un montage optique plus élaboré (Chap.V). Nous allons également démontrer en fin de chapitre la possibilité d'utiliser SPIE600 pour réaliser quelques traitements bas niveaux de l'image à *cadence vidéo* (en utilisant la l'interface électronique/informatique décrite dans l'Ann.D et mise en place pour le besoin d'expériences ultérieures décrites au Chap.VI).

6.1 Modèle du Verre de Spin

Le modèle ferromagnétique et anti-ferromagnétique d'Ising a été exposé au Chap.I,§5.1 : les constantes de couplage entre les spins J_{rs} prennent toutes la même valeur (+1 ou -1 respectivement). Le modèle d'Ising pour le *verre de spin* correspond à une configuration de constantes de couplage *aléatoire*, caractérisée par la probabilité $p \in [0,1]$ d'avoir $J_{rs}=+1$. Le modèle ferromagnétique correspond bien sûr au cas particulier $p=1$, et le modèle anti-ferromagnétique au cas $p=0$. Pour $p \in]0,1[$, on ne connaît pas d'algorithme déterministe permettant de trouver la configuration d'énergie minimale qui soit plus efficace que l'énumération exhaustive de toutes les configurations possibles de *spins* : l'utilisation du recuit simulé est alors justifiée. La fonction d'énergie pour le verre de spin est donnée par :

$$U(e) = \beta_s \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1)(2e(r) - 1) + h \sum_{s \in S} (2.e(s) - 1)$$

La *fig.III.6* représente le *résultat final* du recuit sur SPIE600 dans les trois cas suivants (de gauche à droite dans la figure) : $p=0,8$ (verre de spin), $p=0$ (modèle anti-ferromagnétique) et $p=1$ (modèle ferromagnétique). On observe pour $p=0,8$ la formation de "domaines d'aimantation" en *fin* du recuit. Les cas $p=1$ et $p=0$ (pour lesquels les configurations optimales sont parfaitement connues *a priori*) vont nous permettre d'illustrer quelques particularités du recuit optoélectronique sur SPIE600. En effet, pour $p=1$ un "bon" recuit devrait conduire à une phase finale ferromagnétique *homogène*, (tantôt à +1, tantôt à -1 en fonction de la direction du champ extérieur h "brisant" la symétrie du système). Si le recuit est trop "rapide", alors le système pourra présenter des "domaines d'aimantation", minimisant *localement* l'énergie. En fait, en absence de champ ($h_{pol}=0$ V) la phase finale est presque toujours homogène, et cela même pour un recuit "rapide". Elle possède en outre le signe du *bord* virtuel (voir remarque ci-dessous). Celui-ci agit en brisant la symétrie du système et *force* le signe de la phase finale comme le ferait la présence du champ extérieur.

Remarque : problème des bords. Sur SPIE600, la grille S correspond bien sûr aux 576 sites de la matrice 24×24 , et non pas à un réseau bidimensionnel *infini*. Les bords imposent donc des conditions aux limites particulières. On pourrait rendre ces conditions *périodiques* en interconnectant les PE des bords opposés de la puce, la topologie torique ainsi créée ne privilégiant aucune position particulière sur la grille. Cependant, le circuit SPIE600 fonctionne en créant un bord "virtuel" de PE dont l'état est *figé* pendant le recuit (à $+1$ ou à -1). Le résultat du recuit dépend alors fortement du signe de cette "couronne" (on définit d'ailleurs la température critique du système comme la température maximale pour laquelle les conditions aux bords sont "ressenties" - à l'équilibre thermodynamique - au centre d'une grille carrée quelle que soit la taille de celle-ci [Marro85b]). Malheureusement la possibilité de *couper* les interactions électriques avec ce bord virtuel, - minimisant ainsi l'influence des bords - n'a pas été envisagée. Cependant, cette situation correspond naturellement à celle du montage à interconnexions optiques que l'on étudiera au Chap.V.

Pour $p=0$ (tout comme pour $p=1$) il existe deux configurations d'énergie minimale, "diamétralement opposées" dans l'espace des états (i.e. pour passer de l'une à l'autre, il faut inverser *la totalité* des spins). Néanmoins, dans le cas $p=0$, ni le champ extérieur ni les conditions aux bords ne peuvent privilégier aucun de ces deux minimums énergétiques *d'aimantation nulle*. Il est donc vraisemblable que, si le recuit est opéré un peu trop rapidement, la grille S soit partagée spatialement en domaines correspondant chacun à une configuration d'énergie minimale (damier et damier inverse). C'est ce que l'on peut effectivement observer dans la *fig.III.6-(b)*.

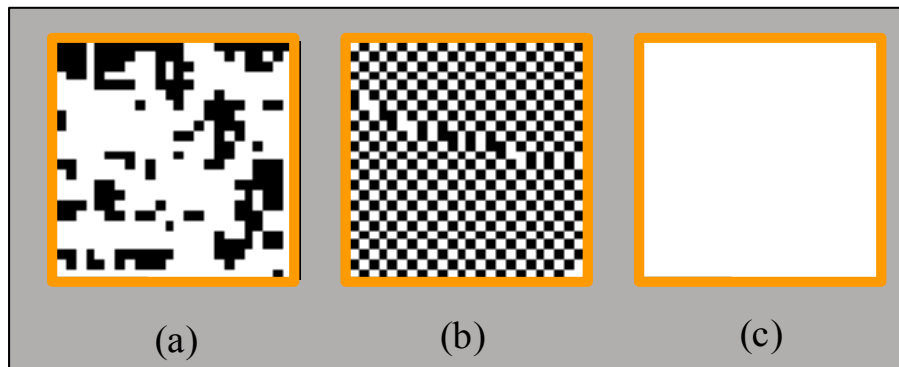


Fig.III.6 : Résultat du recuit pour le modèle d'Ising bidimensionnel (expérience sur SPIE600). (a) Modèle du Verre de Spin avec 80% des couplages à $+1$ (le reste à -1). (b) Modèle anti-ferromagnétique (constantes de couplage négatives). (c) Modèle ferromagnétique (constantes de couplage positives).

L'exemple du verre de spin est étudié plus en détail dans [Prévos95] ; nous aurons cependant l'occasion de reproduire quelques tests validant le prototype en nous appuyant sur l'exemple du *débruitage d'images binaires*.

6.2 Débruitage d'images binaires à cadence vidéo.

Le circuit SPIE600 à *interconnexions électriques* peut fonctionner comme une rétine artificielle pour le débruitage d'images binaires à *cadence vidéo* [Cassin98]. Il suffit pour cela de projeter l'image à traiter sur la surface de la puce (codée en mode double-voie sur chaque photodétecteur différentiel³⁷). Rappelons que la fonction d'énergie à minimiser est dans ce cas :

$$U(e, o) = -\beta_s \sum_{s \in S} \sum_{r \in V(s)} (2e(s) - 1)(2e(r) - 1) - \beta_o \sum_{s \in S} (2.o(s) - 1)(2.e(s) - 1),$$

où $o(s)$, $s \in S$ représente l'image binaire à débruiter (*cf.* Chap.I,§5.1.1). Celle-ci doit donc être codée en double-voie pour pouvoir représenter la quantité bipolaire $2.o(s)-1$ sur chaque paire de photodétecteurs (*cf.* *fig.*V.11).

6.2.2 Test d'échantillonnage avec contrainte aux données optiques.

Comment vérifier que la procédure *d'échantillonnage* opérée sur la puce SPIE600 réalise effectivement la mise en équilibre thermodynamique du champ d'étiquettes, pour une température de speckle et une image binaire de contrainte données? En toute rigueur, il faudrait vérifier que la procédure de mise à jour tend à engendrer, au bout d'un certain temps, des configurations suivant la loi de distribution de Gibbs à la température T (Chap.II.§2.1) :

$$G_T(E = e) = \frac{1}{Z_T} \exp\left(-\frac{U(e)}{T}\right)$$

La vérification exacte de cette distribution à partir d'un large échantillon de configurations s'avère fondamentalement impossible puisque on n'a pas accès à la valeur de la fonction de partition Z_T (il faudrait sommer sur les 2^{576} configurations possibles du champ d'étiquettes pour l'obtenir) ; par ailleurs, il faudrait pouvoir vérifier cette loi sur les éléments de l'espace des configuration Ω_E (et il y en a 2^{576}). On peut tout au plus procéder à la vérification de quelques conditions *nécessaires* - mais pas suffisantes - pour l'obtention de la loi de Gibbs. Tout d'abord, on ne vérifiera pas directement la loi de Gibbs, mais seulement la distribution canonique d'un observable -par exemple l'énergie. On a dans ce cas :

$$\Pr[U = u]_T = C_T \Omega(u) \exp\left[-\frac{u}{T}\right],$$

où $\Omega(u)$ est une fonction indépendante de la température correspondant au degré de dégénérescence de l'énergie u (le spectre est discret), et C_T est une constante qui ne dépend *que* de la température. Ensuite, et puisque $\Omega(u)$ est également une fonction inconnue, nous allons nous en affranchir en travaillant à partir de deux distributions

³⁷ Le dispositif - basé sur des cristaux liquides ferroélectriques - qui permet de réaliser cette opération sera décrit en même temps que le montage optique plus élaboré du démonstrateur final à interconnexions optiques (montage simplifié (E) du Chap.V, §1.1).

correspondant à T_1 et T_2 ; en effet, si l'on suppose que l'expression analytique de la distribution engendrée par le processus d'échantillonnage ne varie pas avec la température³⁸, alors il est possible de s'affranchir de $\Omega(u)$ en calculant le rapport :

$$\frac{\Pr[U = u]_{T_1}}{\Pr[U = u]_{T_2}} = \frac{C_{T_1}}{C_{T_2}} \exp\left[\frac{(T_1 - T_2)}{T_1 T_2} u\right],$$

soit, en prenant le logarithme :

$$\ln \frac{\Pr[U = u]_{T_1}}{\Pr[U = u]_{T_2}} = a.u + b, \text{ avec } a = \frac{(T_1 - T_2)}{T_1 T_2} \text{ et } b = cte(T_1, T_2)$$

Pour deux puissances de speckle données (correspondantes à T_1 et T_2), SPIE600 peut générer rapidement un échantillon large de configurations du champ d'étiquettes ; si l'on calcule pour chacune d'elles l'énergie correspondante (il faut connaître au préalable β_S et β_O) il est alors possible de vérifier la *linéarité* de l'expression ci-dessus et comparer les pentes théorique et expérimentale. La figure *fig.III.7* montre que le logarithme du quotient des distributions canoniques est bien linéaire par rapport à l'énergie ; cependant il existe un écart considérable (de l'ordre de 10% ou plus) entre la pente théorique et expérimentale. Remarquons que le calcul de l'énergie pour une configuration donnée ainsi que la détermination de la température algorithmique dépendent de l'ajustement plus ou moins exact entre les paramètres théoriques et expérimentaux, ajustement qui est fait en *moyennant* sur les différents PEs (Chap.VI. §1.3). La dispersion des caractéristiques entre PEs et le *gradient* de température à la surface de la puce (*cf.* Chap.IV, §1.3.2) peuvent être à l'origine de cet écart. Quoi qu'il en soit, le recuit semble se comporter de façon satisfaisante comme on le verra au paragraphe suivant.

6.2.3 Courbes de recuit.

La relation entre les paramètres théoriques (température T et valeurs β_S et β_O pondérant chaque terme de la fonction d'énergie) et les grandeurs de contrôle expérimentaux correspondants (tension de commande de la diode laser de speckle V_d , tension sur le plot f_pol de SPIE600 et enfin courant I_A alimentant la diode laser du système d'imagerie pour la projection de l'image de contrainte – *cf.* Chap.V) est étudiée en détail au Chap.VI, §1.3. Le recuit est contrôlé depuis l'ordinateur hôte ; un exemple de code est donné dans l'Ann.D, §4. La *fig.III.8* permet de comparer le minimum énergétique atteint par recuit simulé avec celui obtenu par minimisation déterministe (ICM) - dans le cas du débruitage d'images binaires. Le recuit est exagérément lent (nombre d'itérations quatre fois plus grand que pour le recuit sérieux), mais les paramètres ont été choisis

³⁸ C'est à dire que la dynamique du processus ne change pas ; ceci peut s'avérer faux quand on fait varier le paramètre de température de speckle (non linéarités de la détection différentielle peut être, élargissement du spectre d'émission de la source pour des puissances en dessous du seuil laser, qui change les degrés de liberté M du speckle et donc la *forme* de la loi sigmoïde du thermostat, etc.).

pour permettre de bien visualiser la courbe d'évolution de l'énergie ; on obtient des résultats finaux comparables pour des recuits comportant seulement une centaine d'itérations. On remarquera que l'énergie finale obtenue par recuit simulé est non seulement inférieure à celle obtenue par minimisation déterministe, mais elle est également (très légèrement) inférieure à l'énergie de l'image originale non bruitée - un modèle de débruitage idéal devrait faire correspondre le minimum énergétique de la fonction d'énergie avec la configuration reproduisant l'image originale.



Image binaire (24x24) de contrainte aux données.

Pente théorique :

$$m_{th} = (T_1 - T_2) / (T_1 \cdot T_2) = 0,0099$$

$$m_e / m_{th} = 108 \%$$

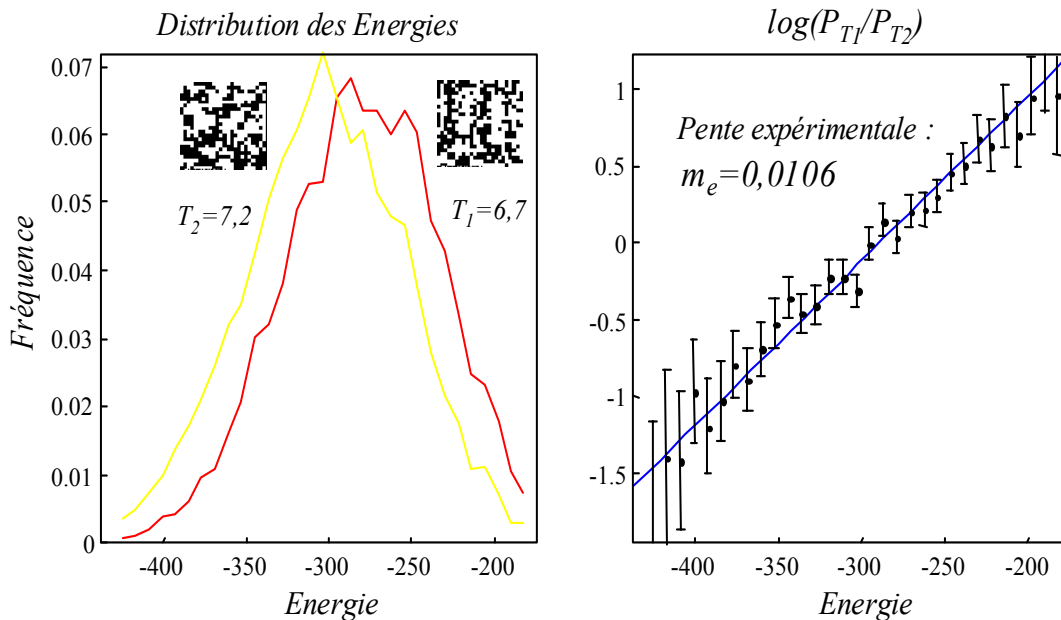


Fig.III.7: test de l'équilibre thermodynamique à partir d'un échantillon de 6000 configuration du champ. Les paramètres expérimentales sont : $I_A=220$ mA, $I_B= 200$ mA, soit $\beta_S=1,02$ et $\beta_C=0,82$.

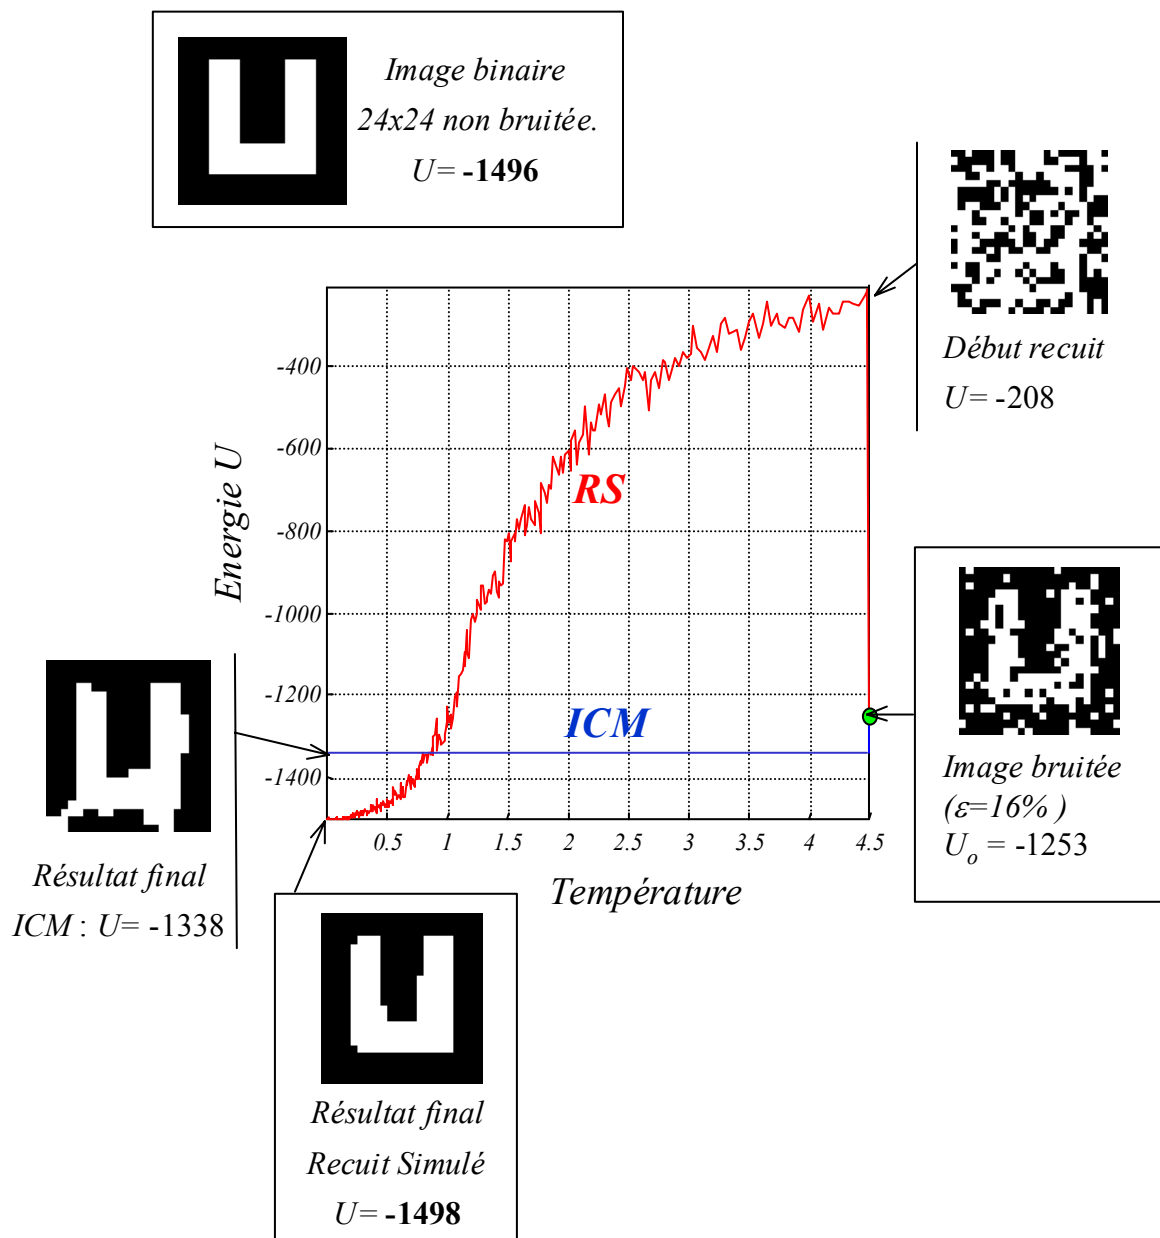


Fig.III.8 : Energie en fonction de la température pendant le recuit simulé (RS) et l'ICM pour la restauration d'une image binaire 24x24 bruitée avec un bruit de canal $\epsilon=16\%$, en utilisant les **interconnexions électriques** aux 4 plus proches voisins du processeur SPIE600. Comparer avec la fig.II.7 du Chap.II.

Paramètres :

Modèle : On a $I_a=220$ mA et $f_{pol}=100$ mV, donc $\beta_C=1,4$ et $\beta_S=1$.

Recuit : $T_i=4,5$; $T_f=0,005$; $r=0,99$ et $nsan=6$ (4062 itérations par recuit).

La procédure ICM correspond à 6 mises à jour du champ avec $T=0$.

6.2.4 Résultats visuels.

La figure *fig.III.9* représente une séquence d'images binaires 24x24 bruitées avec un bruit de canal croissant, ainsi que les résultats correspondant respectivement à la restauration par recuit simulé optoélectronique et par minimisation déterministe (toujours en utilisant le processeur SPIE600). On remarquera que les "conditions aux limites" électriques de la matrice SPIE600 correspondent à un pourtour de PEs virtuels figés dans l'état +1, ce qui perturbe parfois le résultat de la restauration (apparition de pixels parasites aux bords et/ou "fusion" partielle entre l'image et les frontières de l'image).

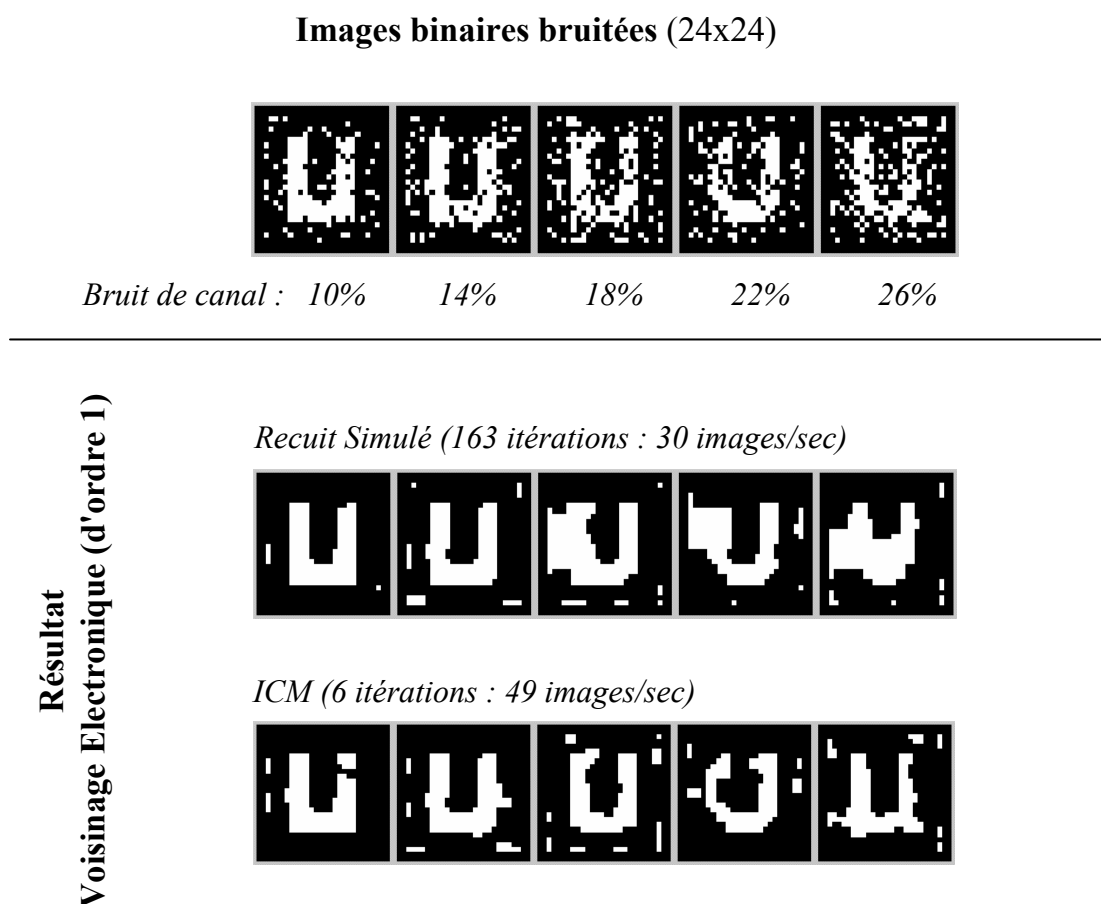


Fig.III.9 : Démonstration pour le débruitage d'images binaires 24x24 en utilisant les interconnexions électriques de SPIE600 (voisinage d'ordre 1).

Paramètres :

Modèle sont : $I_A=220\text{ mA}$ et $f_{pol}=100\text{ mV}$, donc $\beta_C=1,4$ et $\beta_S=1$.

Recuit : $T_i=4,5$; $T_f=0,06$; $r=0,9$ et $nsan=4$, ce qui correspond à 163 itérations par image (au lieu de 1000 pour un recuit sérieux).

7. Conclusion

7.1 Nombre de recuits sérieux à la seconde sur SPIE600.

La fréquence maximale de mise à jour pour un coloriage binaire est de l'ordre de 10 kHz - en utilisant l'interface sous Windows/Matlab décrite dans l'Annexe D (fonction *Boucle_Electronique* pour $nscan=1000$ et $\tau_o=0$). Une *dizaine* de recuits sérieux par seconde³⁹ est en principe possible avec le prototype SPIE600. A titre de comparaison, nous estimons à 10 secondes le temps nécessaire pour effectuer un seul recuit sérieux en simulation sur un ordinateur Pentium 120MHz, pour un problème de taille 24x24.

7.2 Performances pour le débruitage d'images.

Une centaine d'itérations semblent suffisantes (au lieu de 1000 pour un recuit sérieux) pour obtenir un "bon" minimum énergétique dans le cas du débruitage d'images binaires 24x24. On peut en principe traiter une *centaine d'images binaires* à la seconde. Le dispositif à cristaux liquides ferroélectriques utilisé pour l'affichage des images à traiter (*cf.* Chap.V) peut "suivre" en affichant des images pré-enregistrés (cadence maximale de 1250Hz avec l'interface commerciale Slim II de Displaytech - *cf.* Ann.A). Une démonstration pour le *débruitage d'images à cadence vidéo* a ainsi été possible [Cassin98] - la cadence est réduite car il faut récupérer et sauvegarder le résultat de la restauration.

³⁹ On a pu obtenir des cadences supérieures de mise à jour (jusqu'à 100 kHz) en utilisant une interface informatique plus rudimentaire fonctionnant sous MS-DOS. On arrive alors à une *centaine* de recuits sérieux à la seconde. L'utilisation d'une interface informatique sous Windows 32 bits a eu comme effet de réduire considérablement les performances du démonstrateur, mais s'est avérée indispensable pour le contrôle de nouvelles cartes d'entrée-sortie dans le montage optoélectronique final (*cf.* Chap.V et VI et Ann.D).

Chapitre IV

La détection du mouvement

1. Introduction

L'analyse du mouvement se distingue fortement de l'analyse d'images statiques. Premièrement et d'un point de vue pratique, on constate que la contrainte *temps-réel* s'impose presque toujours (pour des applications embarquées par exemple). D'un point de vue traitement du signal, l'analyse du mouvement intègre des *informations temporelles* extraites à chaque instant à partir d'au moins deux clichés de la séquence, voire encore de la séquence toute entière⁴⁰. Les signaux en étude ont à la fois une dimension spatiale et une dimension *temporelle*. Enfin et d'un point de vue algorithmique, l'analyse du mouvement gère des modèles parfois très complexes de la scène observée (modèles d'éclairage variable pour les surfaces des objets tridimensionnels en mouvement, etc.).

On se propose ici de montrer comment on peut appliquer efficacement le formalisme bayésien étudié au Chap.I au problème de la *détection du mouvement*. Il s'agit d'une première étape conceptuellement élémentaire mais qui peut s'avérer cruciale pour aborder correctement une analyse plus approfondie du mouvement. Comme il a été vu à la fin du Chap.I (§4), l'application du formalisme bayésien aux problèmes de traitement d'images bas niveau réalise une "traduction" de ceux-ci en termes de *fonction d'énergie à minimiser*. Les algorithmes de détection du mouvement que l'on étudiera par la suite conduisent tous à la définition de fonctions d'énergie n'ayant pas de propriétés remarquables susceptibles de simplifier cette tâche d'optimisation (convexité de la fonction et continuité du domaine de définition des variables par exemple). Etant donné la contrainte temps-réel, il est important de résoudre ce problème au moins à cadence vidéo, sans qu'il y ait pour autant une dégradation significative de la qualité de la détection. La difficulté du problème a poussé la plupart des chercheurs utilisant des stations de travail conventionnelles à proposer des modèles très simplifiés (taille réduite du champ à optimiser, limitation du nombre de paramètres à estimer) et à se limiter à

⁴⁰ Dans ce cas le traitement sera dit en *temps-différé*, car la durée du traitement dépend de la taille de la séquence, et cette durée dépasse en général le temps imparti au traitement dans une application *temps-réel*.

l'utilisation d'algorithmes d'optimisation déterministes. Cependant, on sait que les procédures d'optimisation stochastiques de type recuit simulé, bien qu'extrêmement gourmandes en calcul donnent théoriquement les meilleurs résultats, indépendamment du modèle de détection choisi. Voilà qui est intéressant : ne pourrait-on pas utiliser un processeur du type proposé au chapitre précédent pour rendre compte de ce problème sans compromettre la contrainte *temps-réel*?

Notre objectif est de démontrer la possibilité d'intégrer un processeur de type PPOS dans une chaîne de traitement d'images à *cadence vidéo*⁴¹. Nous avons choisi en l'occurrence le problème de la détection de mouvement. Il faut tout d'abord -et c'est l'objet de ce chapitre- établir un modèle suffisamment simple pour pouvoir être implanté avec des éléments optoélectroniques conventionnels, sans qu'il y ait pour autant une perte significative de la *qualité* du traitement par rapport aux modèles complexes mais *temps-différés* qui tournent sur station de travail.

2. L'analyse du mouvement

2.1 Introduction

L'analyse du mouvement est une tâche extrêmement complexe impliquant en même temps le développement de capteurs de vision plus ou moins spécialisés ainsi qu'une capacité de calcul très importante capable de traiter un flot de données-images continu. On ne peut expliquer que l'évolution naturelle ait permis le développement de systèmes de vision aussi complexes que l'œil et le cortex visuel que par l'énorme avantage biologique que de tels systèmes confèrent aux organismes les possédant ; il est évident que dans le règne animal (de *animalis* = animé, qui *bouge*), l'information du mouvement est un indice précieux indiquant la présence de la proie ou du prédateur.

Mais le champ du mouvement ne saurait être complètement déterminé par la seule connaissance de la séquence d'images. En toute rigueur, le champ des vitesses est une information supplémentaire à l'interprétation de la scène (comme c'est le cas par exemple dans l'analyse d'écoulements en mécanique de fluides où l'on combine résultats de simulations et expériences parfois complexes et astucieuses -coloration des fluides, méthodes optiques interférentielles- pour essayer de *voir directement* le champ de vitesses). D'un point de vue physique, l'image directe "optique" et l'image indirecte (parfois inaccessible) du champ des vitesses décrivent mieux *ensemble* le phénomène réel, en reconstruisant plus ou moins bien son espace de phases⁴².

⁴¹ En vision artificielle, le terme *temps-réel* est souvent rattaché à la notion de *cadence vidéo*. La cadence de traitement doit être de l'ordre de 25Hz ; ceci conduit, pour des images à 256 niveaux de gris et de taille 256x256 pixels, à un flux de données en entrée qui est de l'ordre de 13Mb/s.

⁴² Remarquons toutefois que l'estimation du champ de vitesses physique dans une scène n'est pas nécessairement le but de l'estimation du mouvement pour tout système de vision ; par exemple, *l'ombre*

Voici le problème qui nous intéresse : en se limitant au seul capteur *d'images*, existe-t-il un moyen de reconstruire *l'espace des vitesses 3-D réel* ? La réponse est certainement -et dans une large mesure- affirmative, puisque nous mêmes sommes capables d'interpréter très efficacement une séquence d'images arrivant sur notre rétine pour en déduire le mouvement réel des objets qui nous entourent. Ceci est possible moyennement un certain nombre d'hypothèses *a priori* et des *modèles* complexes plus ou moins inconscients, innés et affinés par l'expérience quotidienne.

2.2 Hiérarchie fonctionnelle dans les systèmes de vision.

Voici une liste des étapes ou échelons que l'on distingue classiquement à la fois par le niveau *d'interprétation* et par la *complexité du modèle* impliqué dans l'analyse du mouvement :

- *La détection du mouvement.* C'est l'étape la plus élémentaire, visant à distinguer les zones fixes et les zones mobiles d'une séquence d'images. Le champ estimé (appelé carte de détection) est de nature binaire.
- *L'estimation du mouvement.* C'est une étape qui peut encore être traitée dans le cadre de l'analyse *bas niveau* ; il s'agit de déterminer, pour chaque point de l'image, un vecteur vitesse ou déplacement. La carte des vitesses ainsi construite est appelée *flot optique*.
- *La segmentation du mouvement.* Le but est de segmenter l'image en zones homogènes de mouvement. Ces zones vont correspondre vraisemblablement aux différents objets mobiles de la scène ; c'est pourquoi cette opération utilise non seulement les résultats plus ou moins directs du flot optique, mais intègre aussi des modèles des objets mobiles.
- *L'interprétation du mouvement* qualitative (s'agit il d'une translation, d'une rotation) ou quantitative (évaluation d'un torseur cinématique tridimensionnel), la reconnaissance des formes des objets mobiles, etc..

Notons au passage qu'une hiérarchie similaire se retrouve dans le système de vision des vertébrés associé à une surprenante modularité fonctionnelle : tout se passe comme s'il existaient *plusieurs* sens de vision indépendants (mouvements, couleurs, reconnaissance de formes spécifiques - visages, expressions, caractères écrits, etc), dont les résultats fusionneraient pour créer une représentation haut niveau (et unique) du monde (voir *fig.I.2*). C'est une remarque intéressante qui peut nous aider à comprendre que le sens de la vision (comme la plupart des processus cognitifs élaborés) est loin d'être

mouvante d'un lion qui ne se trouve pas dans notre champ de vision ne donne pas lieu à des changements du champ de vitesses *réel* de la scène, mais peut être une information précieuse pour en déduire le mouvement *physique* de celui-ci - et agir en conséquence.

un processus instantané et uni-modulaire comme on aurait eu tendance à le croire jusqu'à il n'y a pas si longtemps⁴³. Il résulte au contraire de l'association d'un grand nombre de modules et de stratégies certainement "découvertes" par hasard et accumulées par voie d'une longue évolution darwinienne. Le résultat est un véritable *patchwork* heuristique (cf. fig.I.2). A fortiori, il est absurde de chercher un modèle mathématique unique pouvant rendre compte en même temps de tous ces processus différents.

3. La détection du mouvement

3.1 Introduction.

Nous allons consacrer le reste du chapitre au problème bas niveau de *détection du mouvement*. Une bonne détection des régions en mouvement peut s'avérer indispensable pour aborder correctement les étapes plus en aval de l'analyse (segmentation des régions en mouvement, amélioration significative de la qualité du calcul classique du *flot optique* -par exemple [Horn81]). Par ailleurs, comme on l'a remarqué en conclusion au Chap.I, les opérations bas niveau en traitement d'images ont beau être élémentaires, elles ne sont pas pour autant celles qui engendrent le moins de calculs - bien au contraire. A elles seules, ces deux considérations suffisent déjà à justifier pleinement que nous ayons porté notre intérêt sur la détection du mouvement comme application potentielle pour notre processeur dédié. En effet, les algorithmes d'optimisation stochastique fournissent théoriquement de bien meilleurs résultats que les algorithmes d'optimisation déterministes : on peut donc espérer l'obtention d'une *carte ou masque* de détection qualitativement très amélioré. D'autre part il ne faut pas oublier que l'un des objectifs de notre recherche sur les processeurs optoélectroniques stochastiques est précisément de démontrer leur capacité à traiter correctement les énormes charges de calcul engendrées par les problèmes de traitement d'images bas niveau à *cadence vidéo*. Mais ce n'est pas tout : la détection du mouvement est à elle seule une opération intrinsèquement intéressante et qui peut s'avérer utile dans un grand nombre de tâches automatiques (contrôle routier, suivi de cibles, compression d'images, etc.). C'est pourquoi, bien que conduisant à une interprétation sommaire de la scène, la détection du mouvement a

⁴³ C'est peut être l'influence d'une conception dualiste qui aurait relégué à l'*âme* toute la responsabilité des processus cognitifs de haut niveau. Pour Descartes par exemple, l'interprétation d'une image est un fait *immédiat* et qui ne souffre pas de description : après avoir décrit assez précisément la formation (optique) des images sur la rétine et l'acheminement de celles-ci "par l'entremise des nerfs optiques, dans la superficie intérieure du cerveau" ("*Les passions de l'âme*", art.XXXV), il continue : "puis de là, par l'entremise des esprits dont ces cavités sont remplies, ces images rayonnent en telle sorte vers la petite glande que ces esprits environnent, que le mouvement qui compose chaque point de l'une des images, tend vers le même point de la glande [...] au moyen de quoy les deux images qui sont dans le cerveau n'en composent qu'une seule sur la glande, qui agissant immédiatement contre l'ame, luy fait voir la figure de cet animal." (Pour un développement passionnant de la conception "fonctionnaliste" moderne, voir l'ouvrage de Daniel.C.Dennett, "Consciousness explained").

suscité très tôt de nombreuses recherches et des réalisations motivées par les applications industrielles, civiles ou militaires.

3.2 Description du problème.

La détection du mouvement consiste à distinguer dans une séquence d'images, les *objets mobiles* par rapport aux objets fixes -et en l'occurrence par rapport à un *fond* fixe. Cette classification s'effectue en affectant une *étiquette* à chacun des points de l'image, et cela pour chaque image de la séquence. Dans le cas le plus simple, un étiquetage binaire suffit conduisant à un *masque binaire des objets mobiles* noté *MB* (pour chaque point de l'image, ou bien celui-ci est fixe, ou bien il est mobile)⁴⁴ ; mais des classifications plus exhaustives peuvent se révéler utiles comme point de départ pour des traitements de plus haut niveau (le *multi-étiquetage* permet de distinguer plusieurs objets différents en mouvement).

La détection du mouvement s'appuie sur l'étude des variations temporelles de la fonction de luminance. Deux hypothèses simplificatrices sont généralement admises :

- d'une part, on suppose le capteur fixe (autrement il faudrait redéfinir la notion de mouvement dans une scène) ;
- d'autre part on suppose que l'éclairage de la scène observé est quasi constant (en principe il ne devrait pas y avoir d'ombres, mais si tel est le cas elles seront traitées comme s'il s'agissait d'objets mobiles).

Dans ces conditions, toute variation temporelle de l'intensité est nécessairement liée soit au mouvement, soit à la présence de bruit. A partir de là, plusieurs approches ont été utilisées pour tenter de reconstruire le *MB*.

⁴⁴ Une remarque tout de suite : le *masque binaire des objets mobiles* (*MB*) et la *carte des changements temporels de l'image* (*CCT* - voir plus loin) sont des choses bien différentes. L'obtention de cette dernière n'est qu'une étape élémentaire dans la construction beaucoup plus élaboré du masque binaire des objets mobiles.

4. Obtention du masque des objets mobiles (MB)

4.1 Utilisation d'une image de référence.

L'idée est de disposer d'une image, dite *image de référence* qui contient exclusivement le fond fixe de la séquence à analyser. A partir de là, tout objet présent dans l'image analysée mais absent de l'image de référence sera considéré comme un objet en mouvement. En pratique, il suffit de calculer la différence entre l'image courante et l'image de référence et de binariser le résultat (ce qui permet du coup un traitement élémentaire du bruit). Cependant, l'obtention de l'image de référence est loin d'être évidente. Une mise à jour est indispensable afin de tenir compte des éventuelles modifications du fond (changement d'éclairage ou changement de "statut" d'un objet, qui peut cesser de se déplacer ou au contraire commencer à bouger).

Plusieurs stratégies ont été proposées pour l'obtention de l'image de référence. Les plus simples se basent sur l'enregistrement direct de la scène dépourvue d'objets mobiles [Marvall95]. Si cela n'est pas possible (c'est à dire dans la plupart des cas), on peut essayer de reconstruire petit à petit l'image de référence à partir de la séquence d'images en cours d'observation [Jain79]. La construction et la mise à jour de l'image de référence peut se faire par filtrage temporel récursif [Bulas93]. Par ailleurs, certains auteurs proposent un filtrage plus élaboré tel que le filtrage prédictif de Kalman [Karman90].

En résumé, si la méthode peut paraître simple, la difficulté d'obtention de l'image de référence restreint son utilisation à des cas particuliers (la technique est surtout utilisée dans l'analyse des scènes routières [Koba87]). Un point intéressant est pourtant le fait que la mise à jour continue de l'image de référence autorise naturellement la prise en compte d'éventuelles variations d'éclairage.

4.2 Utilisation de la carte des changements temporels.

L'introduction d'informations temporelles dans ce modèle se fait par le biais d'une *carte binaire des changements temporels* (CCT), qui découle d'une analyse plus ou moins immédiate de la fonction de luminance par rapport au temps. L'idée est d'obtenir une carte des changements qui se produisent à chaque instant dans l'image, en essayant de minimiser les effets parasites dus au bruit. Comme on le verra par la suite, la carte des changements temporels n'est qu'un premier pas vers la reconstruction du masque des objets mobiles⁴⁵.

⁴⁵ La carte de changements temporels (CCT) seule n'est autre chose que le résultat plus ou moins bien approché par le "filtre de nouveautés".

4.2.1 Obtention de la CCT

Plusieurs méthodes ont été proposées pour aboutir à la carte des changements temporels :

a) Utilisation de la différence inter-image (DI). La technique la plus simple pour aboutir à la carte des changements temporels consiste à étudier la dérivée temporelle de la fonction de luminance, approchée de façon discrète par la différence entre deux images successives⁴⁶ :

$$DI(s,t) = \left| \frac{\partial I(s,t)}{\partial t} \right| = |I(s,t) - I(s,t-1)|$$

Les images réelles n'étant jamais exemptes de bruit, la différence inter-image ne fera que l'amplifier. Néanmoins, étant donné la nature du bruit, celui-ci se verra amplifié *localement* lors de l'opération de dérivation. Il est alors possible de le réduire en réalisant un filtrage passe-bas de la différence inter-images [Diel91].

Toujours à cause du bruit, il est préférable de choisir un *seuil* pour distinguer plus sûrement les points où la variation de luminance est significative (due au mouvement) de ceux où elle est plus faible (donc due au bruit). La carte de changements temporels significatifs est donc obtenue selon :

$$CCT(s,t) = \begin{cases} 0 & \text{si } DI(s,t) < \theta \\ 1 & \text{sinon.} \end{cases}$$

Cette technique de détection a été abondamment utilisée [Aach93], [Lalan90a]. Remarquons que la carte de changements temporels qui en résulte est binaire, et que le seuil θ est un premier paramètre du modèle. Le choix de ce paramètre peut se révéler crucial dans le cas d'images trop bruitées ou peu contrastées. Aussi, dans certains cas – connaissance a priori de la statistique du bruit des objets en mouvement et du fond –, ce paramètre peut être déterminé de façon optimale. Dans d'autres cas, si l'on connaît seulement le modèle du bruit, ce paramètre peut être estimé en temps réel sur la séquence en traitement.

La méthode de différence seuillée présente l'avantage d'être très simple d'implantation. Cependant, l'opération de binarisation pour un pixel donné ne tient compte que de l'information de mouvement qui lui est associé : autrement dit, le résultat est peu robuste vis-à-vis du bruit. Pour renforcer la robustesse des détecteurs de

⁴⁶ On suppose tout le long du chapitre que les images à traiter sont à niveaux de gris ; on pourrait cependant utiliser l'information de couleur pour réaliser une détection de changements temporels plus efficace pour les images en couleur : la DI serait alors donnée par la norme de la différence entre deux vecteurs 1x3 (RGB), et non pas par la différence entre les *projections* de ces mêmes vecteurs sur l'axe des "niveaux de gris".

changements temporels, certains auteurs ont eu l'idée de prendre la décision relativement à un voisinage centré autour du point, et de s'appuyer sur des tests statistiques : c'est ce qui est développé ci-dessous.

b) Méthode de détection des changements à l'aide des test de vraisemblance. Dans ce genre de méthodes, on considère deux fenêtres carrés centrées sur chaque pixel de l'image pour deux images consécutives. Le test est réalisé en calculant les probabilités associées aux hypothèses suivantes (d'où le nom du test) : (1) les fenêtres ont des distributions de gris identiques et (2) les fenêtres ont des distributions différentes, et dans ce cas on considère qu'il y a eu un changement temporel. Différentes modélisations de la distribution des niveaux de gris dans la fenêtre ont été étudiées : modélisation constante [Skif89], modélisation linéaire et modélisation quadratique [Hsu84]. La carte des changements temporels étant binaire, il faut choisir aussi un seuil de binarisation. La plupart du temps ce seuil est fixé de façon arbitraire, mais dans certains cas il peut être estimé à partir des données statistiques [Aach93].

Si l'on ne connaît pas précisément la statistique des images (scènes de rue par rapport aux scènes répétitives dans une chaîne de production par exemple), alors les masques reconstruits après une simple différence seuillée sont en général moins précis et plus bruités que ceux obtenus à l'aide d'une méthode de vraisemblance.

c) Autres méthodes. Remarquons enfin qu'il existe des méthodes permettant d'intégrer de faibles variations d'éclairage dans le calcul de la carte de changements temporels [Skif89], [Ulst73], ainsi que des méthodes basées précisément sur des modèles d'éclairage [Skif89], [Phong75] permettant d'obtenir des cartes de changement temporels pour des images où les objets changent d'*orientation* par rapport à la source lumineuse.

4.2.2 Reconstruction du MB à partir de la CCT.

La carte de changements temporels ne fournit pas directement le masque des objets mobiles. Outre les détections parasites, la carte des changements temporels fait apparaître quatre zones distinctes (voir *fig.IV.1*) :

(1) : le *fond* ou zone *fixe*, où l'amplitude de la différence des niveaux de gris est faible et donc au dessous du seuil de binarisation ;

(2) et (3) : la zone *d'écho*, et la zone de *recouvrement*, constituées respectivement des pixels qui appartenait à l'objet mobile et qui ont été découverts et recouverts suite au mouvement. L'amplitude de la différence y est plus importante, et dépasse le seuil de binarisation θ ;

(4) : la zone de *glissement*, pour laquelle la différence des niveaux de gris est faible et reste en dessous du seuil binarisation. Remarquons toutefois que l'objet mobile peut être texturé -et qu'il est en tout cas rarement uniforme en niveau de gris ; l'hypothèse simplificatrice que nous sommes implicitement en train d'admettre consiste à supposer

que les variations de niveaux de gris sur l'étendue spatiale de l'objet sont moindres que celles que l'on obtient par différence entre n'importe quelle partie de l'objet mobile et le fond.

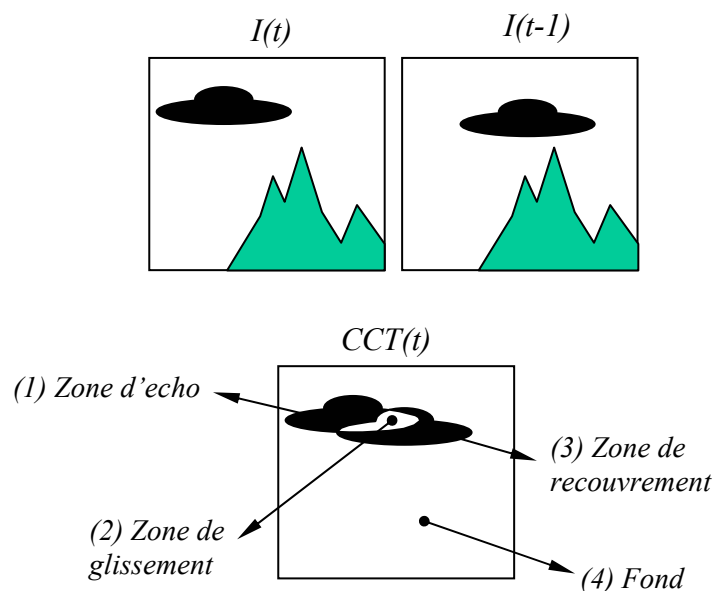


Fig.IV.1: Carte de changements temporels (CCT) obtenue par différence seuillée (ou par test de vraisemblance) entre deux images consécutives.

L'existence de l'ensemble de ces quatre zones dépend d'une part de la fréquence d'acquisition du capteur d'images par rapport à la vitesse l'objet mobile, et d'autre part de la taille des détails de l'objet mobile que l'on doit être en mesure de détecter par rapport à la résolution du capteur d'images. Dans ce qui suit, nous allons nous placer toujours dans l'hypothèse que ces quatre zones existent au moins pour les zones "intéressantes" de l'objet mobile (on dira que la séquence est "bien conditionnée" par rapport aux hypothèses faites au paragraphe §3.2.

Remarquons en particulier que si l'objet mobile possède une texture "fine" (régulière ou pas), et que si la vitesse de déplacement de l'objet est suffisamment élevée par rapport à la cadence du capteur d'images compte tenu de la taille de la texture, alors celle-ci *n'est pas un détail de l'objet mobile* pour lequel la carte des changement temporels puisse fournir les quatre zones en question.

Pour obtenir le MB, il faut traiter la CCT pour (a) éliminer la zone d'écho, (b) intégrer la zone de recouvrement, (c) compléter la zone de glissement et (d) diminuer les détections parasites. Plusieurs stratégies ont été proposées à cette fin :

- Méthode du ET logique [Wiklun87]. Elle consiste a réaliser un ET logique entre les cartes de changement temporels calculées à partir de trois images successives. La méthode est très rapide mais ne donne de bons résultats que s'il n'y a pas de recouvrement entre les positions successives de l'objet mobile (pas de zone de glissement). C'est une condition assez restrictive.

- Certains auteurs proposent l'utilisation d'heuristiques *ad-hoc* pour reconstruire le masque des objets mobiles : moyennant certaines hypothèses plus ou moins arbitraires quant à la taille de l'objet et aux caractéristiques du bruit, [Diel91] propose de regrouper les points isolés avec leurs voisins grâce à un filtre médian 5x5, d'éliminer les zones détectées de trop petite taille, ainsi que de "boucher" les trous à l'intérieur des régions de changement temporel (zones de glissement). La méthode propose donc une régularisation des images provenant d'une connaissance de leur caractéristiques intrinsèques ;
- une méthode plus élégante pour régulariser la carte de changements temporels est d'utiliser la **modélisation markovienne**. Ce formalisme permet la prise en compte de connaissances a priori pertinentes sur la solution cherchée telles que l'homogénéité spatiale et temporelle des masques. Cette approche présente en plus l'avantage de réaliser en même temps le débruitage de l'image et le traitement d'images en mouvement même quand celui-ci est de faible amplitude (remplissage de zones de glissement). Plusieurs variantes du modèle markovien ont été proposées, plus ou moins complexes et plus ou moins particulières, allant par exemple du modèle à vingt paramètres de [Kurians95]⁴⁷ pouvant traiter des objets uniformes en rotation, jusqu'au modèle simplifié de Dumontier [Dumont96] à trois paramètres dont il sera question au chapitre suivant.

4.3 Techniques diverses pour l'obtention directe du MB.

Il serait sûrement inutile de chercher à trouver un algorithme permettant de traiter tous les cas de figure en ce qui concerne la détection du mouvement. Les astuces au cas par cas permettent de faire beaucoup mieux là où les algorithmes trop généraux ne donneraient que des résultats médiocres. En voici quelques exemples n'utilisant pas la méthode de la CCT ni l'image de référence :

- Les méthodes décrites auparavant ne rendent pas compte du mouvement d'objets de petite taille (détection et suivi de corps célestes en mouvement – planètes, satellites naturels ou artificiels -, suivi de cibles lointaines, etc.). En effet, de par leur taille, les modèles précédemment décrits n'y verront que du bruit. Dans [Blostein91], à chaque pixel sont associés plusieurs trajectoires possibles, calculées à partir de tests statistiques dans l'hypothèse d'un mouvement constant. Une autre approche [Letang93] assimile chaque point de l'image à un signal temporel ; une analyse fréquentielle permet alors d'éliminer les variations temporelles parasites, et de faire ressortir les petits objets qui se déplacent lentement.

⁴⁷ la profusion de paramètres est symptomatique -à mon avis- d'une tendance à vouloir donner trop de généralité au modèle (cf. remarque au §2.2) ; à la fin c'est un système beaucoup plus complexe (nous mêmes) qui finit par choisir la valeur des paramètres en fonction du problème.

- Il existe également des méthodes basées sur la détection des contours en mouvement [Vieren88], [Stelma85]. Elles consistent pour la plupart à utiliser conjointement un détecteur de contours et un détecteur de changements temporels.
- Des stratégies multi-échelles ont aussi été adoptées, par exemple dans [Gil93], où la détection des changements temporels est effectuée sur plusieurs niveaux d'une pyramide d'images. La localisation de l'objet mobile est affinée le long de la pyramide en tenant compte des informations de contour provenant du signe de la différence inter-image.

4.4 Conclusion

D'après ce rapide tour d'horizon des diverses techniques de détection de mouvement, il ressort clairement qu'il n'existe pas une méthode universelle permettant de traiter tous les cas de figure. Soit parce que les besoins sont différents (plus ou moins de détail quant à la forme de l'objet, contraintes de temps de calcul, etc.) soit parce les séquences à traiter proviennent elles-mêmes d'origines très différentes, chaque application nécessite le développement de méthodes spécifiques - ou au moins l'adaptation d'une technique déjà existante. La **régularisation markovienne de la carte de changements temporels** semble toutefois se dégager puisqu'elle permet d'intégrer dans le même modèle des informations d'origines diverses, et de s'adapter à tous les besoins par l'ajustement d'un ensemble de paramètres plus ou moins réduit. Cette méthode présente alors le double avantage d'avoir une certaine généralité, tout en respectant un cadre mathématique assez rigoureux - ce qui permet en outre de mieux appréhender la signification et l'importance de chaque paramètre du modèle. Par la suite, nous allons nous concentrer sur la méthode de détection du mouvement basée sur cette technique.

5. Régularisation markovienne de la CCT

5.1 Introduction

Tout comme grand nombre de problèmes en traitement d'images, la détection du mouvement par traitement de la CCT appartient à la classe de problèmes dits *mal posés* : la carte de changement temporels ne donne qu'un *indice* de la solution recherchée (i.e. le masque binaire des objets mobiles MB). La modélisation markovienne propose de restreindre l'ensemble de solutions possibles par l'introduction d'un certain nombre de *contraintes a priori*.

Plus précisément, la régularisation de la carte des changements temporels par *champs de Markov* et *estimation bayésienne*, consiste à : (1) définir un *modèle d'observation* liant la ou les observations (différence inter-image, carte de changements temporels, etc.) avec le champ d'étiquettes binaire ; (2) modéliser le champ d'étiquettes binaires MB par un *champ de Markov* ; et (3) utiliser une procédure d'optimisation - stochastique ou

déterministe - pour obtenir l'estimé du *MAP* du champ d'étiquettes final. Pour éviter les confusions, nous allons noter E le champ d'étiquettes binaires considéré comme un champ aléatoire (MRF) et nous allons réserver la notation MB seulement pour le résultat final de l'estimation : $MB \equiv \hat{e}^{MAP}$ (cf. Chap.I, §2.2).

5.2 Interprétation des variables.

Dans ce qui suit, on reprendra les notations du formalisme probabiliste bayésien et du modèle markovien (cf. Chap.I, §3), tout en donnant une interprétation des variables correspondant au problème de la détection du mouvement.

5.2.1 Modèle d'observation

Les données. Soit $\{I(0), I(1), \dots, I(t)\}$ la séquence d'images à analyser, c'est à dire l'ensemble d'images perçues par le capteur jusqu'à l'instant présent t - dans la pratique, on dispose au plus de quatre ou cinq images en même temps. Comme on vient de le voir, la technique de régularisation de la carte des changements temporels ne s'appuie pas directement sur la donnée image, mais sur la différence inter-image. Par analogie avec les méthodes de traitement d'images statiques pour lesquelles les données à traiter sont directement issues de l'observation, on appellera ce champ *le champ d'observations à valeurs continues* $O(t)$:

$$O(t) \equiv DI(t) = |I(t) - I(t-1)| \quad (1)$$

L'obtention de ce champ implique un prétraitement des données-image. Afin de réduire le bruit, on utilise parfois un filtre passe bas (masque $\frac{1}{4}[1 \ 2 \ 1]$ en ligne et en colonne) avant de calculer la différence. Dans le cas de véritables traitements spatio-temporels, le champ d'observation est constitué lui aussi de plusieurs champs bidimensionnels : $O = \{O(1), \dots, O(t)\}$. Enfin, certains modèles conservent le signe de la dérivée temporelle, ce qui permet de différencier la zone d'écho de la zone de recouvrement.

Enfin, la carte de changements temporels (CCT) est bien sûr un champ de contraintes aux données (qui peut ou non résulter de la différence inter-image par simple seuillage cf. §4.2.1). Par la suite, on appellera ce champ *le champ d'observations binaires*. Il sera noté $\hat{O}(t)$ et l'on a alors :

$$\hat{O}(t) \equiv CCT(t) \quad (2)$$

Lien entre étiquettes et observations. Le lien entre le champ de mouvement binaire E et les champs d'observations - $O(t)$ et/ou $\hat{O}(t)$ - n'est pas immédiat comme c'est le cas par exemple dans le problème de la restauration d'images bruitées (cf. Chap.I, §5.1). Tout d'abord, il n'existe pas une définition claire de ce qu'est la *détection du mouvement* (l'ombre d'une automobile en mouvement est-elle bien un objet en *mouvement* qui doit être détecté? le "bruit" présent dans l'image provenant par exemple d'un nuage de poussière ou de la pluie ne provient-il pas d'un phénomène de *mouvement*?). Le modèle

dépend très étroitement de l'objectif recherché, mais celui-ci n'est pas non plus très simple à définir.

On se bornera par la suite à la description détaillée de quelques modèles mettant en jeu de fonctions prédéfinies plus ou moins *ad-hoc* ; dans ces modèles, le lien entre le champ d'étiquettes binaires et le champ d'observation continu est défini formellement par :

$$O = \Psi(E) + B,$$

où B est un vecteur de bruit gaussien non corrélé en espace et en temps, et Ψ est une fonction prédéfinie [Lalan90a]. Par ailleurs, on remarquera que dans ces modèles, le champ d'observation binaire (i.e. la carte des changements temporels $\hat{O}(t)$) n'impose pas directement une contrainte sur le champ d'étiquettes, mais sur *la forme des potentiels des cliques* du champ spatio-temporel de Markov. Sans casser complètement un lien temporel, le champ $\hat{O}(t)$ tantôt réduit le poids d'une interaction, tantôt l'augmente : il est l'équivalent d'un *bord* tridimensionnel (invariable pendant le calcul), qui rajoute *a priori* des informations locales sur la forme finale du champ d'étiquettes.

5.2.2 Le champ de Markov (masque binaire des objets mobiles ou champ d'étiquettes E).

Champ de Markov spatio-temporel. Comme on l'a dit auparavant, la détection du mouvement consiste à déterminer l'état de mouvement de chaque pixel de chaque image de la séquence. Il s'agit, comme pour tant d'autres problèmes de traitement bas niveau, d'un problème de *segmentation*. La seule différence réside dans le fait que les données sont à la fois spatiales et temporelles. Pour chaque séquence d'images $I(s,t)$, le résultat de l'estimation serait idéalement une séquence de même longueur, c'est à dire un champ d'étiquettes binaire tridimensionnel : le *masque spatio-temporel binaire des objets mobiles* $MB(s,t)$, issu d'une segmentation spatio-temporelle des pixels (fig.IV.2).




Fig.IV.2 : Resultat de la segmentation spatio-temporelle : le champ d'étiquettes final correspond au masque spatio-temporel binaire des objets mobiles MB.

Cependant, la contrainte temps-réel implique un traitement *causal* : on ne dispose pas de la séquence préenregistrée depuis le début jusqu'à la fin. A chaque instant, les données futures sont inaccessibles. Par ailleurs, pour une question de difficulté d'implantation, toutes les techniques présentées vont se restreindre au traitement d'une tranche temporelle très fine du champ spatio-temporel de labels -voir à un *seul* champ spatial $E(t)$. Les labels en dehors de cette tranche seront considérés comme constants et ne seront pas relaxés pendant la phase d'optimisation.

Forme du voisinage spatio-temporel. La *fig.IV.3* illustre un exemple de voisinage spatio-temporel : le champ de Markov est défini à tout instant par l'ensemble des trois champs binaires $E(t-1)$, $E(t)$ et $E(t+1)$. Un voisinage plus simple que celui de la figure (voisinage d'ordre 1 aux 6 plus proches voisins par exemple) peut favoriser la reconstruction des masques d'objets à contours horizontaux ou verticaux, ainsi que celle des masques des mouvements de translation horizontaux ou verticaux.




Fig.IV.3 : Voisinage spatio-temporel du site s -aux 18 plus proches voisins- et cliques binaires associées : en gras, les cliques spatiales ; en tirets les cliques temporelles ; en tirets plus fins, les cliques spatio-temporelles.

Potentiel des cliques. Les potentiels des cliques spatiales sont fixés une fois pour toutes et sont invariants par translation spatiale : ils caractérisent le degré de régularisation spatiale du masque binaire du mouvement. Par contre, le potentiel de la clique temporelle peut être contrôlé par la valeur locale (en temps et en espace) du champ d'observation binaire $\hat{O}(t)$. La raison en est que si en un site donné on a mesuré un *changement*, il est probablement lié à un changement de *l'état de mouvement réel*: il faut alors neutraliser la liaison qui force le site présent et passé à avoir la même valeur -ou même en inverser le poids.

On distinguera les vrais modèles spatio-temporels des modèles spatiaux à *contrainte temporelle* : dans ces derniers, il n'existe pas de véritable voisinage temporel. Le champ de Markov est associé exclusivement au champ d'étiquettes courant $E(t)$, tandis que les champs $E(t-1)$ - et/ou $E(t+1)$ - sont *gelés* pendant la régularisation de $E(t)$ et agissent comme des champs de *contrainte*. Dans ces modèles, si les liaisons temporelles restent abusivement représentés par des cliques, la raison en est que l'énergie de contrainte temporelle est souvent déduite par simplification d'un véritable modèle spatio-temporel.

5.2.3 Energie globale, force locale et optimisation.

On a vu au Chap.I,§4 que le choix de l'estimateur MAP rendait le problème équivalent à celui de la minimisation d'une fonction d'énergie ayant deux termes : un terme de *régularisation* et un terme d'attache aux données de *l'observation* (les notations minuscules correspondent aux réalisations des variables aléatoires) :

$$U(e, o) = U_{obs}(e, o) + U_{reg}(e)$$

La fonction d'énergie est parfaitement définie une fois que l'on a choisi le modèle d'observation et la forme du voisinage (topologie et potentiels de cliques). On est alors à même de calculer la *force locale* ou *gradient* au site (s, t) :

$$F(s, t) = -\Delta U(e / o, \delta) \Big|_{e(s,t)=0}^{e(s,t)=1},$$

quantité nécessaire à la mise à jour locale (stochastique ou déterministe) du champ d'étiquettes (plus la force définie ci-dessus sera grande, et plus le site aura des chances de voir son étiquette changée à +1, *cf.* Chap.II,§2.2.2). L'opération est répétée pour tous les sites (de façon séquentielle ou parallèle), en variant le paramètre de contrôle T , jusqu'à obtention du champ optimal (recuit simulé, *cf.* Chap.II,§2.3). En raison de l'importante charge de calcul engendrée par l'optimisation stochastique, la plupart des auteurs ont dû se satisfaire de méthodes déterministes sous-optimales (ICM par exemple). Il est intéressant de noter que plusieurs d'entre eux (par exemple [Memin93]) choisissent d'estimer *a posteriori* la qualité des résultats du modèle *temps-réel* par rapport à ceux obtenus en utilisant une procédure de recuit simulé en *temps-différé*.

5.3 Description des algorithmes de Lalande et Dumontier.

Les algorithmes développés dans [Dumont96] et [Caplie95] sont des versions simplifiées de l'algorithme de détection du mouvement originellement décrit dans [Lalan90a], véritable modèle spatio-temporel trop gourmand en calcul pour être aujourd'hui correctement implanté sur des ordinateurs séquentiels conventionnels. Le temps de calcul est en réalité la *seule* raison pour laquelle ces deux auteurs ont cherché à simplifier le modèle original, (1) en réduisant de façon conséquente le nombre de variables à calculer (un seul champ d'étiquettes à relaxer au lieu de deux champs couplés, les modèles ne sont plus spatio-temporels, mais à *contrainte temporelle*), et (2)

en utilisant des techniques d'optimisation extrêmement rapides mais loin d'être optimales (méthodes déterministes de type ICM). Les performances se trouvent bien sûr compromises, mais pas au point de ne pas justifier une réalisation expérimentale (carte DSP [Dumont96], simulation d'un réseau VLSI [Caplie95]).

Notre processeur optoélectronique est dédié à l'optimisation stochastique en temps-réel. La rapidité de calcul est telle que l'on pourrait en principe implanter le modèle complet de Lalande sans compromettre ni les résultats, ni même la contrainte de *cadence vidéo*. Cependant, le nombre de variables et le caractère continu de certaines d'entre elles rendraient la tâche beaucoup trop ambitieuse (système optoélectronique compliqué mais pas irréalisable) par rapport à notre objectif, qui - rappelons-le - est de *démontrer* l'intérêt de tels processeurs dédiés aux tâches de traitement d'images bas niveau. C'est pourquoi, l'obtention d'un algorithme de détection du mouvement extrêmement simple devenait une nécessité (un seul champ à relaxer à la fois, priorité sur les modèles à variables *binaires* pour éviter les problèmes d'uniformité d'éclairage, etc.). Nous sommes donc parti du modèle à contrainte temporelle de Dumontier-Caplier, que nous avons cherché à étudier pour en dégager les caractéristiques principales. Notre modèle modifié est extrêmement simple, mais il reprend en fait certaines heuristiques présentes dans l'algorithme original de Lalande et négligés dans l'algorithme de Dumontier-Caplier. Le nouveau modèle proposé semble se comporter au moins aussi honorablement que celui de Dumontier-Caplier, au moins pour les quelques cas de figure que nous avons pu étudier (*cf* Ann.C). Nous nous proposons par la suite de discuter avec plus ou moins de détail des modèles de Lalande et Dumontier-Caplier pour en extraire les idées fortes.

5.4 Un modèle complet mais gourmand en calcul : le modèle de Lalande.

On présentera par la suite le modèle de Lalande [Lalan90a], qui peut être considéré comme le point de départ de notre travail. Il s'agit d'un véritable modèle spatio-temporel quoique de faible "épaisseur temporelle".

5.4.1 Données et modèle d'observation.

Le modèle de Lalande fait appel au champ d'observations $O(t)$ continu et aussi au champ d'observations binaire $\hat{O}(t)$. Dans ce modèle où seul est considéré simultanément le champ de Markov spatio-temporel formé par le *couple glissant* $\{E(t), E(t+1)\}$, la relation entre l'observation $O(s,t)$ (à l'instant t et au site s) et la paire d'étiquettes (aux instants t et $t-1$) s'écrit simplement :

$$O(s,t) = \Psi_L(E(s,t), E(s,t-1)) + n,$$

(n est une variable gaussienne centrée de variance σ^2). Le potentiel Ψ_L est défini par le tableau *tab.IV.1*.

$e_t(s)$	$e_{t-1}(s)$	$\Psi_L \{ e_t(s), e_{t-1}(s) \}$
0	0	0
0	1	m_2
1	0	m_2
1	1	m_1

Le choix de la fonction Ψ_L s'interprète de la façon suivante : si le site était fixe à l'instant $t-1$ et reste fixe à l'instant t (transition fond-fond), alors il est vraisemblable que l'observation non bruitée - la différence inter-image $o(s,t)$ - soit *nulle* dans ce site. Lors d'une transition objet-objet (zone de glissement) l'observation est proche d'une valeur m_1 qui dépend des caractéristiques de l'objet, mais qui reste *faible* devant la variation de luminance m_2 entraîné par une transition fond-objet (zone de recouvrement) ou objet-fond (zone d'écho). C'est la traduction formelle des hypothèses faites au §3.2.

La fonction d'énergie associé au processus d'observation (cf.Chap.I,§2.3) s'écrit alors (les indices permettent de simplifier l'écriture pour la variable temporelle) :

$$U_{obs}(e_{t-1}, e_t / o_t) = \sum_{s \in S} V_o(e_{t-1}(s), e_t(s), o_t(s)) ,$$

$$\text{avec } V_o(e_{t-1}(s), e_t(s), o_t(s)) = \frac{1}{2\sigma^2} [o_t(s) - \psi_L(e_{t-1}(s), e_t(s))]^2$$

Commentaires. Le modèle d'observation de Lalande présuppose donc :

(a) que les variations spatiales de luminance sur *l'étendue* de l'objet mobile sont moindres que celles qui existent *entre* l'objet et le fond. Autrement dit, les objets mobiles sont supposés uniformes⁴⁸ ; cette hypothèse est plus probablement vérifiée pour des objets de petite taille ;

(b) que le *bruit* est le même pour l'objet et pour le fond. C'est le cas si le bruit provient uniquement du système d'acquisition (et non d'une quelconque variation temporelle de l'éclairage due au mouvement par exemple). Le choix de la statistique gaussienne est certainement arbitraire pour un certain nombre de cas. Remarquons aussi que si le système d'acquisition est tel que $I(t) = I_{originale}(t) + n_{gaussien}$, (hypothèse largement admise) alors le bruit sur l'observation, qui n'est autre chose que la différence inter-image en valeur absolue $O(t) = DI(t) = |I(t) - I(t-1)|$ n'est pas lui même gaussien.

(c) Enfin, le champ d'observation *binnaire* $\hat{O}(t)$ n'intervient pas directement comme une contrainte aux données (il n'engendre pas un terme d'énergie d'attache aux données), mais contrôle les interactions temporelles du champ de Markov (voir ci-dessous).

⁴⁸ le modèle aura du mal par exemple à détecter correctement le mouvement - évident pour l'œil - d'un zèbre ou d'un tigre se déplaçant sur une pelouse parfaitement uniforme ; il n'est pas adapté non plus au cas où fond et objet possèdent la même texture (une raie sur un fond marin de sable par exemple). Mais c'est en réalité une affaire de paramètres : si la résolution augmente, chaque grain de la texture sera considéré comme un objet mobile. Remarquons aussi que pour l'œil, si l'objet ne bouge pas, il passe inaperçu ; mais

5.4.2 Champ d'étiquettes et voisinage.

Le champ d'étiquettes est représenté à chaque instant par le couple glissant $\{E(t), E(t-I)\}$. Le voisinage et les cliques binaires associées sont représentées sur la *fig.IV.4*.

Potentiel spatial V_S . Il s'agit d'un potentiel à deux niveaux qui favorise la continuité spatiale du masque :

$$\forall (r,s) \in S \times S, \quad V_S(e_i(r), e_i(s)) = \begin{cases} -\beta_S & \text{si } e_i(r) = e_i(s) \\ +\beta_S & \text{si } e_i(r) \neq e_i(s) \end{cases} \quad \text{avec } \beta_S > 0,$$

où β_S est un paramètre constant et global (indépendant du temps et du site spatial considéré). On écrira souvent le potentiel à niveau de type V_S sous la forme équivalente :

$$V_S(e_i(s), e_i(r)) = -\beta_S \cdot (2 \cdot e_i(s) - 1)(2 \cdot e_i(r) - 1)$$

Potentiel temporel V_T . La valeur du potentiel temporel est dépendante de la donnée d'observation binaire $\hat{O}(t)$. Le tableau *tab.IV.2* définit la valeur locale du potentiel temporel.

$e_{t-I}(s)$	$e_t(s)$	$\hat{o}_t(s)$	V_T
0	0	0	$-\beta_T$
0	0	1	$+\beta_T$
1	0	0	$+\beta'_T$
1	0	1	$+\beta'_T$
0	1	0	$+\beta_T$
0	1	1	$-\beta_T$
1	1	0	$+\beta_T$
1	1	1	$-\beta_T$

Tab.IV.2 : Définition du potentiel temporel

Les configurations associées à $-\beta_T$ sont favorisées, les autres défavorisées. β'_T prend une valeur très élevée afin d'éliminer presque certainement la configuration improbable $(1,0,0)$, ou la configuration $(1,0,1)$ dont la gestion doit être décalée dans le temps.

dès qu'il se déplace il est étonnant de constater la facilité avec laquelle nous sommes capables d'isoler la forme en mouvement.




Fig.IV.4 : Voisinage spatio-temporel et cliques binaires associées dans le modèle de Lalande [Laland90].

-Le voisinage spatial est d'ordre 2 ; les potentiels de cliques sont invariants par translation.

-Le voisinage temporel est d'ordre 1. Le potentiel de la clique temporelle est localement contrôlé par la donnée binaire $\hat{o}(s,t)$.

-En pointillés est représentée la contrainte aux données observées $o(s,t)$ et la "clique" associée de potentiel V_O (à valeurs continues).

rem. : les potentiels à niveaux V_S et V_T sont représentés par leurs valeurs $(\pm\beta_S, \pm\beta_T$ ou $\beta'_T)$.

5.4.3 Energie globale et force locale.

Pour résumer, la fonction d'énergie du modèle de Lalande se compose de deux termes :

$$U(e/o_t, \hat{o}_t) = U_{obs}(e_{t-1}, e_t/o_t) + U_{reg}(e_{t-1}, e_t/\hat{o}_t),$$

où l'on a :

- $U_{obs}(e_{t-1}, e_t/o_t) = \frac{1}{2\sigma^2} \sum_{s \in S} [o_t(s) - \psi(e_{t-1}(s), e_t(s))]^2$ est l'énergie d'attache aux données ;
- $U_{reg}(e_{t-1}, e_t/\hat{o}_t) = U_S(e_{t-1}) + U_S(e_t) + U_T(e_{t-1}, e_t/\hat{o}_t)$ est l'énergie de régularisation spatio-temporelle avec :

$$U_S(e_t) = \sum_{(s,r) \in C_S} V_S(e_t(s), e_t(r)) = -\frac{\beta_S}{2} \sum_{s \in S} (2.e_t(s) - 1) \sum_{r \in V'(s)} (2.e_t(r) - 1) \text{ et}$$

$$U_T(e_{t-1}, e_t/\hat{o}_t) = \sum_{(s,r) \in C_S} V_T(e_{t-1}(s), e_t(r), \hat{o}_t(s)).$$

La force locale correspondante au site s et au temps t est alors composée de trois termes :

$$F(s,t) = F_S(s,t) + F_T(s,t) + F_O(s,t),$$

avec respectivement :

- $F_S(s,t) = \sum_{r \in V(s)} \{-V_S[1, e_t(r)] + V_S[0, e_t(r)]\} = \beta_S \sum_{r \in V(s)} (2 \cdot e_t(r) - 1)$, (régularisation spatiale).
- $F_T(s,t) = -V_T(e_{t-1}(s), 1, \hat{o}_t(s)) + V_T(e_{t-1}(s), 0, \hat{o}_t(s))$, (régularisation temporelle).
- $F_O(s,t) = -V_O(e_{t-1}(s), 1, o_t(s)) + V_O(e_{t-1}(s), 0, o_t(s))$, (force de rappel à l'observation).

Commentaires. La forme du potentiel temporel permettrait une implantation électronique-logique immédiate (il s'agit de potentiels à niveaux discrets) ; en effet, on a après calcul pour la force de rappel temporelle au site (s,t) :

$e_{t-1}(s)$	$\hat{o}_t(s)$	$F_T(s,t)$
0	0	$\beta_T + \beta'_T$
0	1	$-2\beta_T$
1	0	$\beta_T - \beta'_T$
1	1	$-\beta_T - \beta'_T$

Par contre, même si la fonction prédéfinie Ψ_L du modèle d'attache aux données est très simple (tab.IV.1), la force de rappel à l'observation reste à *valeurs continues* ; on a :

$$F_O(s,t) = -\frac{1}{2\sigma^2} \left[\psi_L^2(e_{t-1}, 1) - \psi_L^2(e_{t-1}, 0) - 2 \cdot o_t(s) \cdot \{\psi_L(e_{t-1}, 1) - \psi_L(e_{t-1}, 0)\} \right],$$

soit plus explicitement :

	si $e(t-1,s) = 1$:	si $e(t-1,s) = 0$:
$F_O(s,t)$	$-\frac{(m_1 - m_2)}{2\sigma^2} [(m_1 + m_2) - 2 \cdot o_t(s)]$ $\approx \frac{m_2}{2\sigma^2} [m_2 - 2 \cdot o_t(s)]$	$-\frac{m_2}{2\sigma^2} [m_2 - 2 \cdot o_t(s)]$

Tab.IV.3 : force de rappel à l'observation dans le modèle de Lalande.

Letab.IV.3 va nous permettre de mieux interpréter la simplification introduite plus loin dans notre modèle (où la force de rappel à l'observation est à *valeurs discrètes* ; voir aussi fig.IV.7).

5.4.4 Algorithme d'optimisation.

La minimisation de la fonction d'énergie est effectuée par relaxation déterministe de type ICM. A chaque instant t , on obtient le champ estimé $E(t-1)$ et une *première* estimation du champ $E(t)$, utile pour l'initialisation des champs $E(t)$ et $E(t+1)$ à l'instant suivant. L'optimisation par couples glissants permet de revenir à l'instant $t+1$ sur la décision prise à l'instant t , et ceci permet de mieux gérer les zones de glissement et/ou d'éliminer la zone d'écho. La fig.IV.5 donne une synoptique de l'algorithme de Lalande.

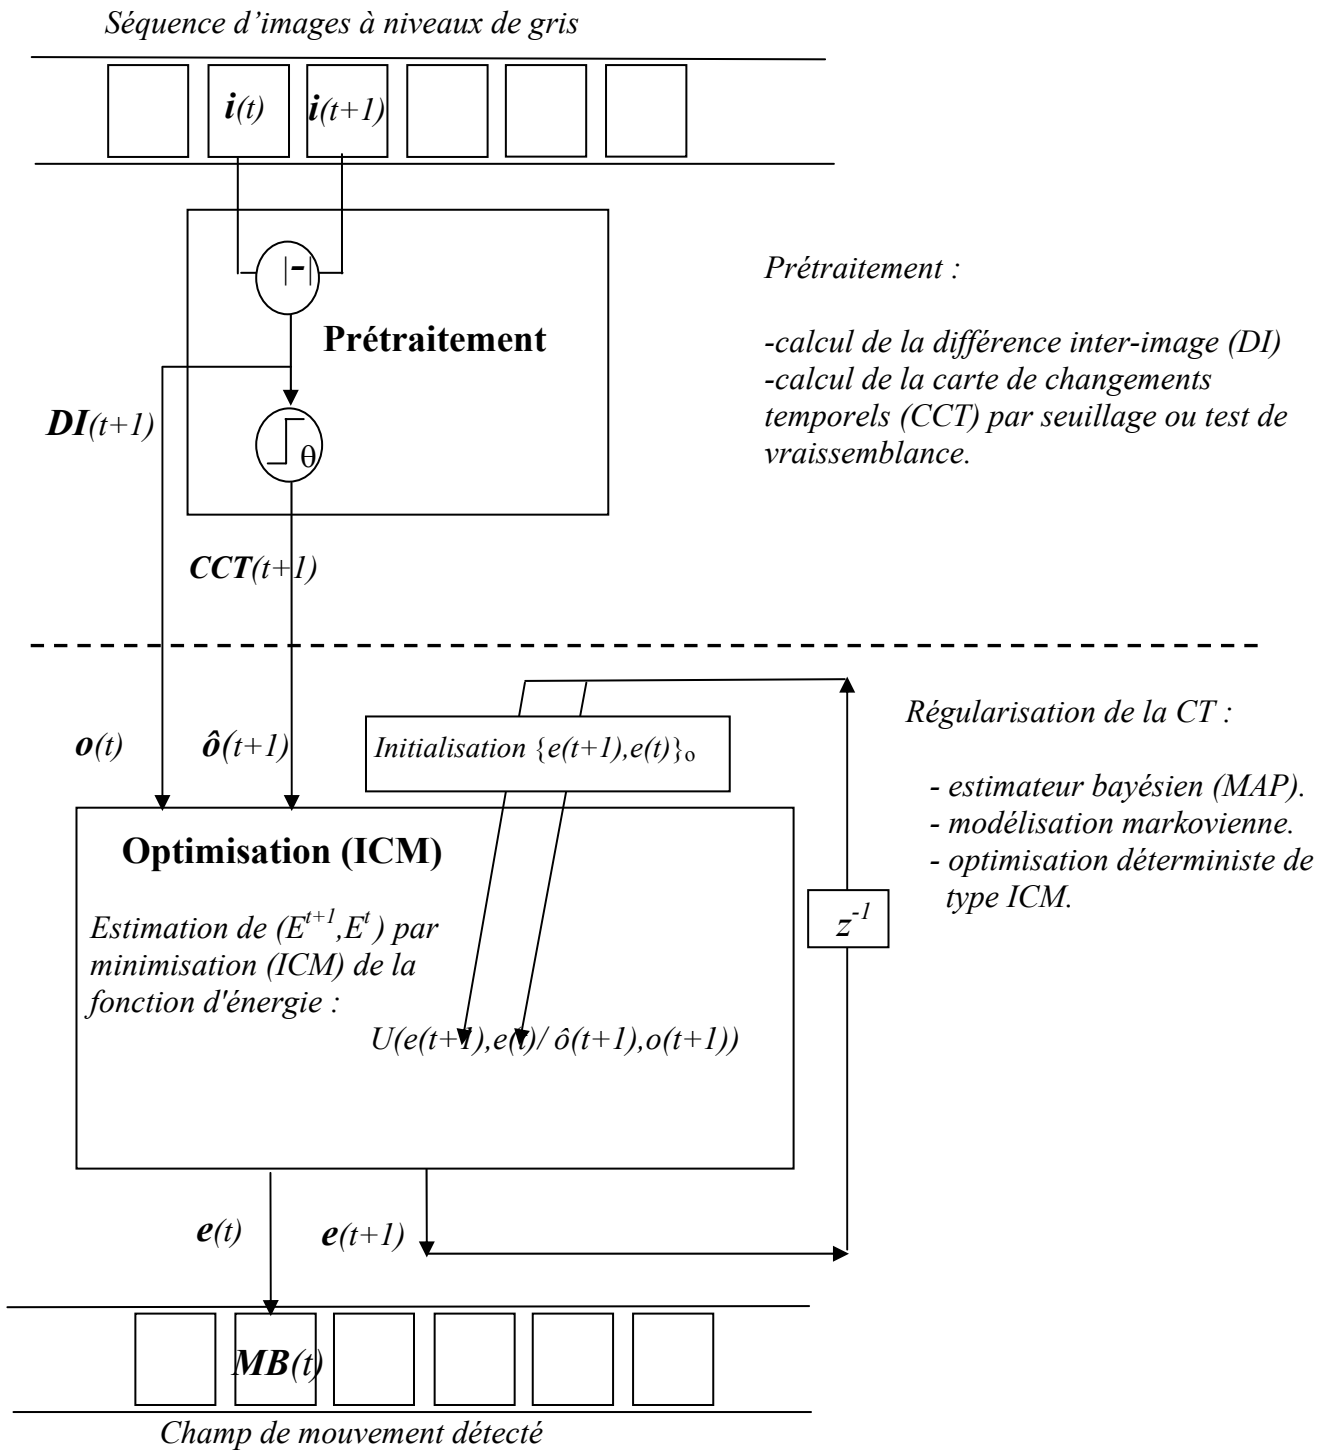


Fig.IV.5 : Schéma synoptique de l'algorithme de détection du mouvement proposé dans [Lalande90]. Le prétraitement se résume au calcul de la CCT binaire par seuillage (ou test de vraisemblance) entre deux images successives. Le champ de mouvement est estimé par couples glissants. Le calcul est réalisé par optimisation déterministe de type ICM. L'initialisation du couple est réalisé grâce au résultat précédent de l'estimation.

5.4.5 Conclusion

Ce modèle fait apparaître des véritables cliques spatio-temporelles, mais seulement dans une tranche temporelle de maigre épaisseur. L'avantage -qui est de pouvoir un peu mieux gérer les zones de glissement- n'est pas si grand face à la complexité introduite (estimation conjointe de deux champs d'étiquettes). En ce qui nous concerne, puisque la relaxation conjointe de plusieurs champs de d'étiquettes en même temps impliquerait une architecture totalement différente pour notre processeur (plusieurs processeurs tableau en cascadié par exemple), il serait aussi facile d'implanter un modèle spatio-temporel beaucoup plus complet (par exemple comportant cinq à huit coupes temporelles [Caplier95]).

5.5 Le modèle simplifié de Dumontier.

Le modèle de Dumontier [Dumont96] tend de réduire la complexité du modèle de Lalande en ne considérant qu'un champ $E(t)$ à estimer à la fois. $E(t-1)$ est donc fixe pendant la durée de l'optimisation. Il s'agit d'un modèle markovien spatial à *contrainte temporelle* selon notre définition. On a changé les notations originales et re-interprété quelque peu les termes pour permettre une présentation cohérente des différents modèles.

5.5.1 Données et modèle d'observation

Les données retenues par le modèle de Dumontier sont les mêmes que celles de Lalande ($O(t)$ et $\hat{O}(t)$). Toutefois, Dumontier et Caplier [Caplie95] semblent s'accorder sur le fait que le calcul de la CCT en utilisant la méthode de vraisemblance n'apporte pas d'amélioration significative quant au résultat final (robustesse de la modélisation markovienne qui traite le bruit en même temps que la régularisation de la CCT).

Le lien statistique entre observations et étiquettes à l'instant t est décrit par une fonction Ψ_D inspirée de Ψ_L , mais qui ne fait intervenir que le champ d'étiquettes actuel :

$$o_t(s) = \Psi_D(e_t(s)) + n, \text{ avec } \Psi_D(e_t(s)) = \begin{cases} 0 & \text{si } e_t(s) = 0 \\ \alpha > 0 & \text{si } e_t(s) = 1 \end{cases}$$

L'interprétation est cette fois-ci la suivante : si le site en question appartient à la zone fixe de l'image, il n'y a pas de changement temporel significatif de luminance. En revanche, si le site appartient à une zone en mouvement, on considère qu'il y a changement temporel, et on suppose l'observation proche d'une valeur $\alpha > 0$. Cette valeur est estimée de façon heuristique dans [Caplier95]. La conclusion semble être que l'on peut fixer ce paramètre une fois pour toutes quel que soit la séquence sans qu'il y ait de dégradation du résultat de la détection.

L'énergie d'attache aux données s'écrit alors :

$$U_{obs}(e, o) = \sum_{s \in S} V_o(e_t(s), o_t(s)),$$

$$\text{avec } V_o(e_t(s), o_t(s)) = \frac{1}{2\sigma^2} [o_t(s) - \Psi(e_t(s))]^2$$

Commentaire : L'élimination de $E(t-1)$ comme entrée de la fonction Ψ_D est à notre avis une simplification beaucoup trop grande. Il est beaucoup plus raisonnable de considérer (d'après les hypothèses faites au §3.2) qu'un changement temporel est le résultat d'une variation de l'état de mouvement du pixel (zone de recouvrement ou zone d'écho), et non du mouvement lui-même (zone de glissement). Lalande considère en effet que cette dernière éventualité conduit à une observation d'amplitude m_2 *beaucoup plus petite* que celle induite par un changement d'état de mouvement ($m_2 \ll m_1$). L'élimination du champ $E(t-1)$ comme champ à estimer ne doit pas conduire à son élimination dans le modèle d'observation, d'autant plus que comme on le verra par la suite, celui-ci est gardé en mémoire pour définir une *contrainte temporelle* sur le champ $E(t)$.

5.5.2 Champ d'étiquettes et voisinage

Comme dit plus haut, le modèle de Dumontier-Caplier ne considère - à chaque instant - qu'un champ de Markov d'étiquettes $E(t)$ sans dimension temporelle. La fig.IV.6 représente le voisinage de Markov spatial et les contraintes aux données.

Potentiel spatial V_S . La forme du potentiel spatial est la même que pour le modèle de Lalande.

Potentiel temporel passé (V_P) et futur (V_F). Dumontier définit deux potentiels à niveaux, associés aux cliques temporelles pour le passé et pour le futur. Il s'agit d'un abus de langage, puisque les champs $E(t-1)$ et $E(t+1)$ ne forment pas partie du champ de Markov en cours de relaxation. En réalité, il s'agit de potentiels de *contraintes aux données* :

- On a pour la contrainte au passé :

$$V_P(e_t(s)/e_{t-1}(s)) = \begin{cases} -\beta_P & \text{si } e_t(s) = e_{t-1}(s) \\ +\beta_P & \text{si } e_t(s) \neq e_{t-1}(s) \end{cases} \text{ avec } \beta_P > 0,$$

où $e(t-1) = MB(t-1)$ est le masque binaire du mouvement estimé lors de la relaxation à l'instant $t-1$. Il est *figé* à l'instant t , et agit comme un champ de contrainte au passé.

- Et pour la contrainte au "futur" :

$$V_F(e_t(s)/e_{t+1}(s)) = \begin{cases} -\beta_F & \text{si } e_t(s) = e_{t+1}(s) \\ +\beta_F & \text{si } e_t(s) \neq e_{t+1}(s) \end{cases} \text{ avec } \beta_F > 0,$$

où $e(t+1)$ est estimé très grossièrement, puisqu'il est pris égal à la carte de changements temporels future $\hat{o}(t+1) = CCT(t+1)$.

Commentaire : la contrainte aux données passées semble bien traduire la contrainte de régularisation temporelle du champ spatio-temporel dans le modèle de Lalande. Le terme de "contrainte aux données futures" est quant à lui un peu plus douteux, puisque l'estimée du champ binaire futur $e(t+1)$ est en réalité le champ d'observation binaire $\hat{O}(t+1)$: on peut se demander alors s'il est vraiment utile d'introduire deux contraintes de rappel aux données (V_O et V_F), et en tout cas pourquoi l'une mettrait en jeu la différence inter-image, et l'autre la différence inter-image seuillée (voir fig.IV.6).




Fig.IV.6 : Cliques spatiales et contraintes aux données dans le modèle de Dumontier. Il est facile de représenter l'énergie d'attache aux données par des potentiels de cliques, mais les 'sites' achurées ne forment pas partie du champ de markov (leur valeurs sont fixes pendant la relaxation du champ $e(t)$). Les potentiels à deux niveaux V_S et V_F sont représentés par leurs valeurs respectives $(\pm\beta_S, \pm\beta_F)$.

5.5.3 Energie et force de rappel locale

L'énergie associée au modèle de Dumontier s'écrit finalement :

$$U(e/o_t, \hat{o}_{t+1}) = U_{obs}(e_t/o_t) + U_{reg}(e_t/e_{t-1}, \hat{o}_{t+1})$$

où : $U_{obs}(e_t/o_t) = \frac{1}{2\sigma^2} \sum_{s \in S} [o_t(s) - \psi_D(e_t(s))]^2$ est l'énergie d'attache aux données, et

$U_{reg}(e_t/e_{t-1}, \hat{o}_{t+1}) = U_S(e_t) + U_P(e_t/e_{t-1}) + U_F(e_t/\hat{o}_{t+1})$ est l'énergie de

"régularisation" spatiale et temporelle⁴⁹, avec :

$$\begin{cases} U_S(e_t) = \sum_{(s,r) \in C_S} V_S(e_t(s), e_t(r)) = -\frac{\beta_S}{2} \sum_{s \in S} (2.e_t(s) - 1) \sum_{r \in V(s)} (2.e_t(r) - 1) , \\ U_P(e_t/e_{t-1}) = \sum_{s \in S} V_P(e_t(s)/e_{t-1}(s)) = -\beta_P (2.e_t(s) - 1)(2.e_{t-1}(s) - 1) \text{ et} \\ U_F(e_t/\hat{o}_{t+1}) = \sum_{s \in S} V_F(e_t(s)/\hat{o}_{t+1}(s)) = -\beta_F \sum_{s \in S} (2.e_t(s) - 1)(2.\hat{o}_{t+1}(s) - 1) \end{cases}$$

⁴⁹ Comme expliqué plus haut, du point de vue de la relaxation du champ de Markov, les termes temporels doivent être considérés comme des *contraintes aux données* ; on entend ici *régularisation* temporelle dans le sens particulier signifiant que le *résultat* de la relaxation précédente doit ressembler au *résultat* de la relaxation courante.

La force locale correspondante au site s (au temps t) est alors :

$$F(s,t) = F_O(s,t) + F_P(s,t) + F_S(s,t) + F_F(s,t), \text{ avec}$$

$$\left\{ \begin{array}{l} F_O(s,t) = V_O(1/o_t(s)) - V_O(0/o_t(s)) = \frac{\alpha}{\sigma^2} \left[o_t(s) - \frac{\alpha}{2} \right], \\ F_P(s,t) = V_P(1/e_{t-1}(s)) - V_P(0/e_{t-1}(s)) = \beta_P (2.e_{t-1}(s) - 1), \\ F_S(s,t) = \sum_{r \in V_S(s)} [V_S(1, e_t(r)) - V_S(0, e_t(r))] = \beta_S \sum_{r \in V_S(s)} (2.e_t(r) - 1) \text{ et} \\ F_F(s,t) = V_F(1/\hat{o}_{t+1}(s)) - V_F(0/\hat{o}_{t+1}(s)) = \beta_F (2.\hat{o}_{t+1}(s) - 1). \end{array} \right.$$

La force locale fait apparaître quatre termes. Le seul terme provenant véritablement d'une modélisation markovienne est le terme de régularisation spatiale F_S . Les trois autres sont en réalité des termes *d'attache aux données* :

- F_P est un terme d'attache au *résultat de l'estimation précédente* $e(t-1) = MB(t-1)$ (qui est fixe et ne peut pas être re-estimé à l'instant t comme dans le modèle de Lalande). C'est la seule véritable *contrainte temporelle*.

- Les deux autres termes F_O et F_F sont des termes d'attache aux données provenant respectivement du champ d'observation continu $O(t)$ et du champ d'observation binaire $\hat{O}(t+1)$. Il est certainement abusif de considérer F_F comme un terme de régularisation *temporelle*, puisque $\hat{O}(t+1)$ n'est qu'une estimation très grossière de $MB(t+1)$. Autrement dit, le modèle de Dumontier n'est pas simplement un modèle simplifié de Lalande : une nouvelle définition *du processus d'observation* a été implicitement mise en place, sans qu'il y ait une véritable justification théorique ; on peut se demander en particulier pourquoi prendre un terme d'attache aux données *continu* au temps t , et un terme d'attache *discret* à l'instant suivant.

- La force de rappel à l'observation F_O est à valeurs continues. La forme est équivalente à celle du modèle de Lalande seulement dans le cas où le site considéré était fixe à l'instant $t-1$ (fond et zone de recouvrement), et l'analogie se poursuit en posant $m_2 = \alpha$ (cf. deuxième colonne du *tab.IV.1*). La force de rappel joue alors correctement *dans le sens de d'intégration de la zone de recouvrement*. Pourtant, le comportement peut être aberrant si le site était *mobile* à l'instant précédent (zone d'écho et zone de glissement). En effet, si l'observation continue $o(s,t)$ est inférieure au seuil $\alpha/2$ (ce qui est vraisemblable pour les sites appartenant à la zone de glissement dans le cas d'objets uniformes), la force de rappel à l'observation tend à *empêcher le remplissage de la zone de glissement* ; et si l'observation dépasse ce seuil (ce qui est certainement le cas pour la zone d'écho), alors la force tend à maintenir l'état de mouvement courant, *rendant difficile l'élimination de la zone d'écho* (voir *fig.IV.7*). En d'autres termes, la force de rappel à l'observation définie selon le modèle de Dumontier n'est pas adapté aux

hypothèses faites au §3.2, mais correspond plutôt au cas d'objets mobiles texturés, bruités et/ou sur lesquels l'éclairage est fortement variable (cas de surfaces changeant d'orientation par rapport à la source lumineuse, par exemple) ; lesdits objets se déplaçant sur un fond constant ayant éventuellement le *même* niveau de gris moyen que l'objet mobile. C'est une situation intéressante, mais qui n'est pas compatible avec celle pour laquelle ont été conçues les autres termes de la force locale.

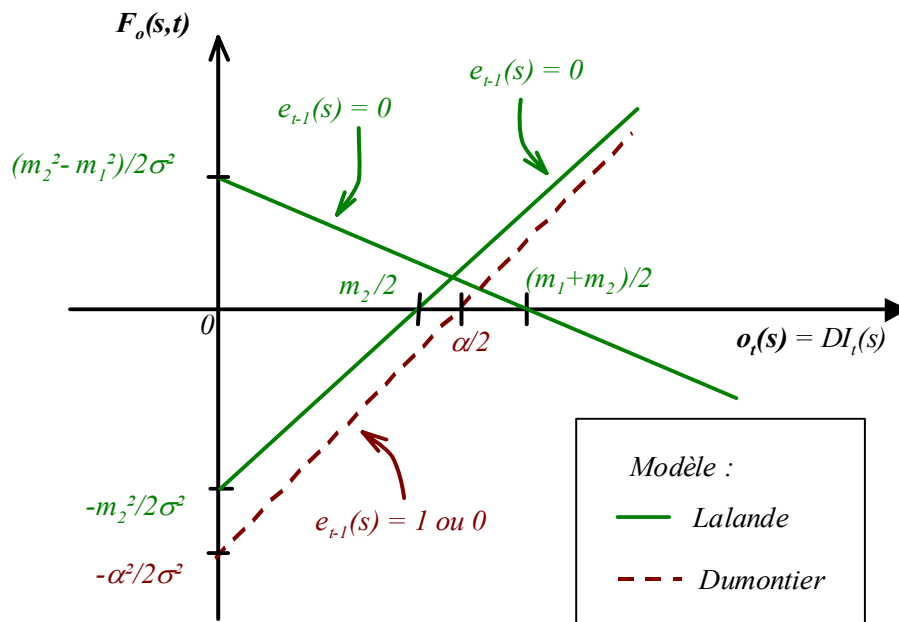


Fig.IV.7 : Force de rappel à l'observation dans le modèle de Lalande et de Dumontier. La force "tire" vers l'état de mouvement 1 si elle est positive, et vers l'état immobile si elle est négative. Le modèle de Dumontier ne distingue pas les cas $e_{t-1}(s)=1$ et 0 .

5.5.4 Optimisation

La méthode choisie par Dumontier est l'ICM. Le balayage de l'image est séquentiel, ligne par ligne, et la mise à jour des sites est dite site-récurrente (dès qu'un site est étudié, la modification éventuelle de son étiquette est immédiatement prise en compte). La convergence est supposée atteinte lorsque la variation relative de l'énergie d'une itération à l'autre est inférieure à une valeur prédéfinie. Le nombre d'itérations avant convergence varie en fonction de l'amplitude du mouvement entre deux images successives, et de la qualité des champs initiaux. Néanmoins, une étude plus approfondie [Caplier95] montre que dans le cas de séquences d'images pour lesquelles les déplacements restent modérés par rapport à la cadence d'acquisition, il est possible d'arrêter la relaxation après un nombre d'itérations fixé une fois pour toutes sans dégradation sensible des résultats. Quatre itérations sur l'ensemble de l'image semblent alors suffisantes. La fig.IV.8 donne une synoptique de l'algorithme de Dumontier pour la détection du mouvement.

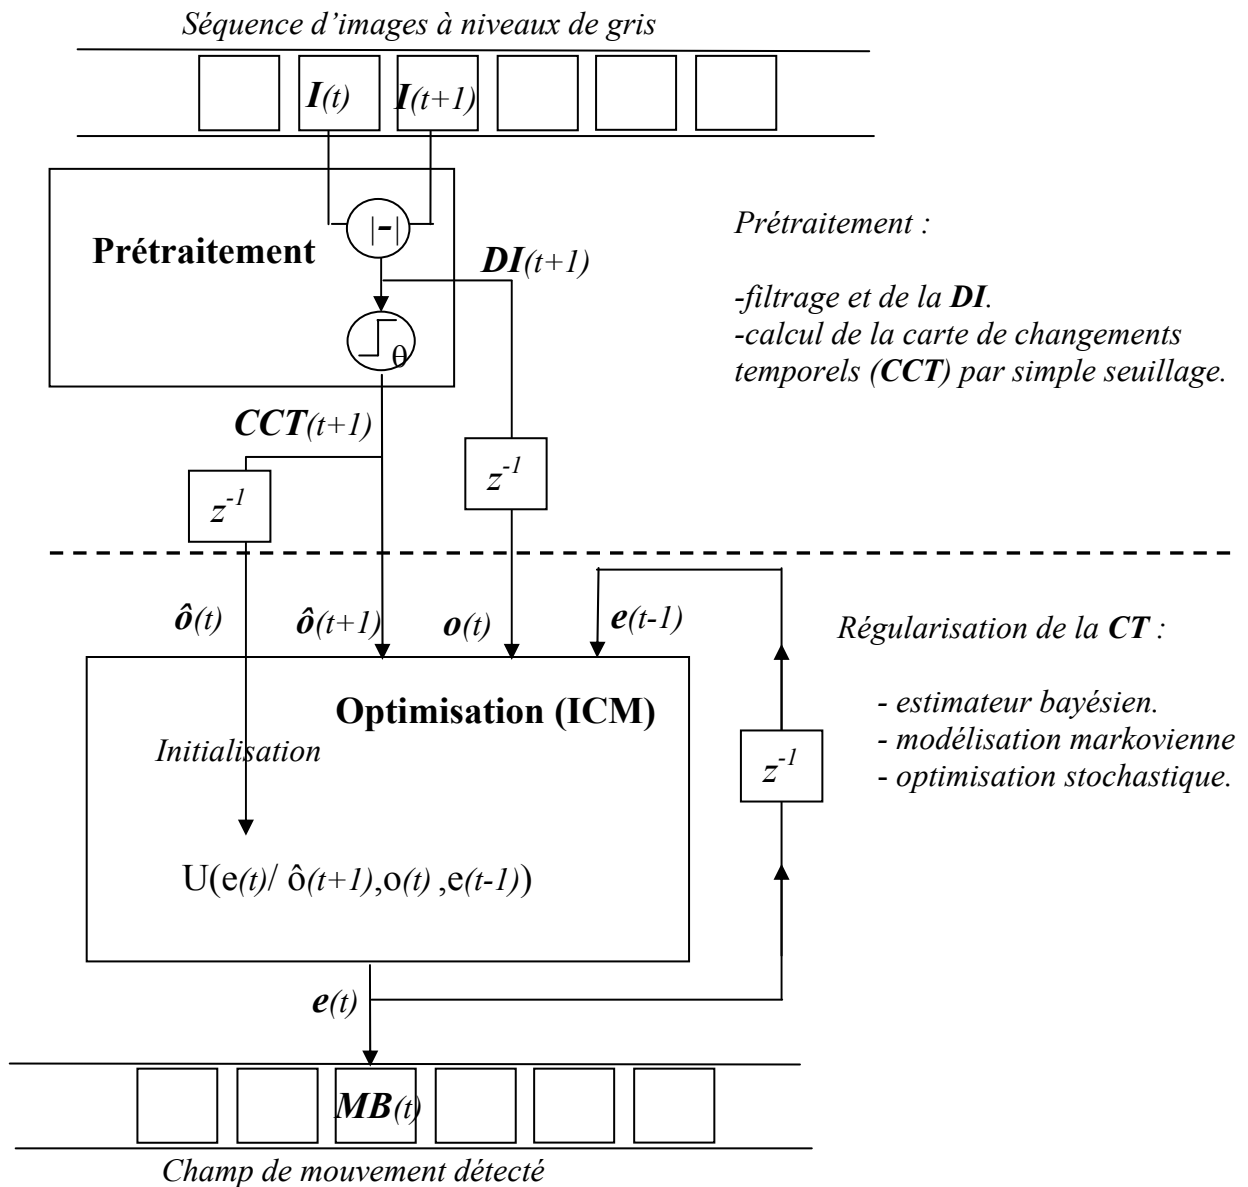


Fig.IV.8 : Schéma synoptique de l'algorithme de détection du mouvement proposé dans [Dumont96]. Le prétraitement se résume toujours au calcul de la CCT binaire par seuillage (avec ou sans pré-filtrage passe bas). Le calcul de l'estimé du champ du mouvement $MB(t)$ est réalisé par optimisation déterministe de type ICM ; celle-ci est très sensible à la valeur initiale du champ $e(t)$: dans le modèle de Dumontier, celui-ci est initialisé comme $\hat{o}(t)$, c'est à dire avec la carte binaire des changement temporels.

5.6 Estimation des paramètres.

Les deux algorithmes décrits nécessitent le choix de deux sortes de paramètres : (a) ceux correspondant exclusivement au modèle de détection du mouvement, et (b) les paramètres de contrôle de la procédure de relaxation (critère d'arrêt). Ainsi, le modèle de Lalande nécessite le choix de 7 paramètres pour le modèle correspondant à la :

1. force de régularisation temporelle : β_T , β'_T et choix du seuil de binarisation θ .
2. force de régularisation spatiale : β_S
3. force de rappel aux données : m_1, m_2 et l'estimation de σ (variance du bruit).
4. Le modèle de Dumontier quant à lui nécessite le choix de 6 paramètres :
5. force de *rappel* temporelle : β_P
6. force de régularisation spatiale : β_S
7. force de rappel aux données observées : α et σ (variance du bruit) pour F_O et seuil de binarisation θ et β_F pour F_F .

En ce qui concerne les paramètres du modèle, Dumontier fait un choix heuristique qui semble convenir pour toutes les séquences en étude, à savoir : $\beta_P = 10$, $\beta_S = 20$, $\beta_F = 30$, et $\alpha = 20$. La variance du bruit de l'observation est estimée périodiquement (à partir de deux images consécutives), et le seuil de binarisation est choisi de façon expérimentale en fonction de la séquence analysée (typiquement entre 25 et 45 pour des images à 256 niveaux de gris et pour des scènes de rue en lumière ambiante).

Enfin, le critère d'arrêt est déterminé -aussi bien dans le modèle de Dumontier que celui de Lalande- de façon heuristique (4-5 itérations de la procédure *ICM*).

5.7 Conclusion

Comme expliqué au §4.2.2, pour régulariser la *CCT* il faut (a) remplir la zone de glissement, (b) éliminer la zone d'écho, (c) intégrer la zone de recouvrement et (d) éliminer le bruit -il n'y a pas d'ordre chronologique entre les opérations. On peut repérer ces différentes fonctions dans les termes de la force locale de Lalande (§5.4.3) et Dumontier (§5.5.4):

(a) remplissage de la zone de glissement :

- Modèle de Lalande : c'est le rôle de $F_S + F_T$ (modèle markovien spatio-temporel).
- Modèle de Dumontier : le remplissage est réalisé grâce à F_O à condition que l'objet présente du bruit et/ou une texture fine (autrement, la force de rappel à l'observation agit de manière à *éliminer* la zone de glissement!). Ensuite F_S permet le remplissage par homogénéisation grâce au modèle *markovien spatial* et F_P agit de façon "indirecte" par *rappel* temporel, une fois le processus de remplissage "amorcé" par F_O et F_S .

(b) élimination de la zone d'écho (transition *objet-fond* : $e_{t-1}(s) = 1$ et $o_t(s)$ grand) :

- Modèle de Lalande: $F_O(s,t)$ (voir *fig.IV.7*).
- Modèle de Dumontier : la valeur de l'observation $o(s,t)$ est certainement importante dans la zone d'écho, ce qui fait que $F_O(s,t)$ fait la promotion (de façon erronée) de l'étiquette *mobile* pour la zone d'écho ; de même, le terme de rappel temporel $F_P(s,t)$, contribue à maintenir l'étiquette erronée. L'élimination de la zone d'écho ne s'appuie donc que sur le terme de rappel au "futur" $F_F(s,t)$ qui est négatif (le champ 'futur' n'est autre chose que la CCT future, en principe *nulle* dans la zone d'écho courante). C'est probablement la raison pour laquelle il faut que $\beta_F > \beta_P$.

(c) intégration de la zone de recouvrement (transition *fond-objet* : $e_{t-1}(s) = 0$ et $o_t(s)$ grand) :

- Modèle de Lalande : $F_O(s,t)$ (voir *fig.IV.7*).
- Modèle de Dumontier : $F_O(s,t)$, qui se comporte exactement comme dans le modèle de Lalande (voir *Fig.IV.g*). Par contre, $F_F(s,t)$ n'aide à l'intégration de la zone de recouvrement qu'à condition que la CCT y soit *non nulle*, mais on peut voir que cela se produit seulement si l'objet au temps $t+1$ a fait un "saut" et n'a aucun recouvrement avec l'objet à l'instant t ; enfin, $F_P(s,t)$ contribue *négativement* (c'est son rôle *conservateur*).

(d) élimination du bruit :

- Modèle de Lalande : F_S et F_T (modèle markovien spatio-temporel).
- Modèle de Dumontier : F_S (modèle markovien spatial) et F_P de façon indirecte.

Une certaine *redondance* dans la fonctionnalité des termes est inévitable -la régularisation markovienne traite le bruit en même temps qu'elle complète la zone de glissement-, mais les tendances *antagonistes* devraient idéalement être réduites à celles (aussi inévitables) qui se présentent entre les termes de *rappel* et ceux de *régularisation*. Comme on vient de le voir, ce n'est pas le cas pour plusieurs termes de la force locale dans le modèle de Dumontier ; cependant, grâce à un choix judicieux (mais heuristique) des paramètres, le modèle donne finalement des résultats satisfaisants.

Remarquons enfin que tant dans l'algorithme de Lalande comme dans celui de Dumontier, l'initialisation du champ d'étiquettes (nécessaire au bon fonctionnement de la procédure d'optimisation déterministe) avec la CCT contribue de façon positive pour les opérations (c) et (d), mais de façon négative pour (a) et (b).

6. Modèle proposé pour la détection du mouvement

6.1 Introduction

Nous allons présenter maintenant un nouvel algorithme de détection de mouvement simplifié, inspiré toujours de celui de Lalande, mais dont :

(a) **l'origine de chacun des termes de la force locale est clairement justifiée** par la nécessité de réaliser une au moins des opérations de reconstruction de la CCT énumérés au §4.2.2. Ceci permet en particulier une bonne interprétation physique des paramètres et éventuellement une estimation automatique, non heuristique. Le modèle de Lalande présente une grande clarté dans ce sens sauf pour ce qui concerne le modèle d'observation (voir deuxième commentaire au §5.4.1) ; c'est loin d'être le cas pour le modèle de Dumontier-Caplier (voir commentaire au §5.7). La justification passe par expliciter clairement les hypothèses du modèle ; nous allons nous intéresser aux séquences vérifiant les hypothèses faites au §3.2 (la force de rappel à l'observation du modèle de Dumontier est inadaptée).

(b) **toutes les opérations de reconstruction de la CCT sont représentées** par au moins un terme de la force locale.

(c) **les termes de la force locale ne sont pas en contradiction fonctionnelle** (sauf entre les termes de *rappel* aux données et ceux de *régularisation*, ce qui est naturel étant donné qu'il s'agit d'un modèle de *régularisation contraint*). Cette "contradiction" est présente dans le modèle de Dumontier-Caplier (comportement antagoniste de F_O , F_F et F_P à l'heure de traiter la zone d'écho).

(d) enfin, et *seulement* pour des raisons d'implantation matérielle (car, a priori, cela appauvrit le modèle) on cherchera aussi à **discretiser les valeurs de la force de rappel à l'observation**.

6.2 Description du nouveau modèle

6.2.1 Données et modèle d'observation.

L'analyse faite au paragraphe précédent conduit tout d'abord à l'élimination de $\delta(t+1)$ comme donnée du modèle (la $CCT(t+1)$ n'est certainement pas une bonne approximation de $MB(t+1)$). A présent on ne considère que l'observation $o(t)$ comme donnée pertinente à l'instant t . Cependant, et dans le seul but de simplifier le codage optique dans le démonstrateur, nous allons prendre la version seuillée du champ $o(t)$, c.à.d. le champ *d'observation binaire* $\hat{o}(t)$ (remarquons toutefois que \hat{o}_t ne représente en aucun cas une estimée du masque des objets mobiles, ni futur, ni passé). On a étoffé ensuite le modèle d'observation qui présentait l'inconvénient de ne pas distinguer les transitions *objet-fond* et *fond-objet* (ce qui induisait au comportement aberrant de la force de rappel à l'observation dans le modèle de Dumontier). On reprend ainsi la définition -plus sensée-

du lien statistique entre observations et étiquettes du modèle de Lalande, à ceci près que l'on choisit le champ d'observation binaire $\hat{o}(t)$ comme donnée du modèle, dégradé par un bruit de canal N :

$$\hat{o}_t(s) = \begin{cases} \Psi_A(e_{t-1}(s), e_t(s)), & \text{si } N = 1 \\ 1 - \Psi_A(e_{t-1}(s), e_t(s)), & \text{si } N = 0 \end{cases}$$

La fonction Ψ_L est remplacée par Ψ_A binaire, obéissant au tableau *tab.IV.4* ci-dessous (il s'agit d'une version simplifiée du tableau *tab.IV.1*, où $m_1=0$ et $m_2=1$) :

$e_t(s)$	$e_{t-1}(s)$	Ψ_A
0	0	0
0	1	1
1	0	1
1	1	0

Tab.IV.4 : Définition du potentiel d'attache aux données pour notre modèle. Le seul paramètre à ajuster est le seuil de binarisation θ , ce qui peut être fait automatiquement à partir des statistiques de bruit de l'image (voir paragraphe suivant).

L'interprétation de la fonction Ψ_A est très simple et sensée : en absence de bruit, $\hat{o}(s,t)=\Psi_A[e_{t-1}(s),e_t(s)]$ et l'observation binaire n'est pas nulle *que s'il y a eu un changement d'état de mouvement*. C'est la situation correspondant à la zone d'écho et à la zone de recouvrement ; compte tenu des hypothèses faites au §3.2, il est vraisemblable que pour un choix approprié du seuil de binarisation, on ait en effet $\hat{o}(s,t)=CCT(s,t)$.

Modèle de bruit.

Le modèle de Lalande considère un vecteur de bruit gaussien s'ajoutant à l'observation continue $O(t)$. Le choix - inspiré de modèles courants en restauration d'images - n'est pas très bien justifié dans le cas de la détection du mouvement. Dans le nouveau modèle proposé il est possible de trouver une interprétation exacte pour le vecteur de bruit : celui-ci n'est plus un bruit gaussien centré, *mais un bruit de canal de taux d'erreur ε* .

Supposons que l'image $I(t)$ issue du capteur est elle-même brouillée par un bruit gaussien centré de variance σ^2 (hypothèse facilement vérifiée dans un grand nombre de cas), et que le niveau de gris est m_o pour l'objet et m_f pour le fond⁵⁰. Calculons la probabilité pour que l'évaluation de la *CCT* avec un seuil de binarisation θ conduise à une décision erronée :

- Pour une transition *fond-fond* ou *objet-objet* ($\Psi_A = 0$), l'observation $\hat{o}(s,t)=CCT(s,t)$ devrait être *nulle*. La probabilité d'erreur vaut (voir *Fig.IV.h*) :

⁵⁰ En toute rigueur le fond et l'objet mobile peuvent être bruités (bruit constant ou variable dans le temps) et/ou texturés. Nous n'allons pas modéliser ces phénomènes ; nous allons nous restreindre aux cas pour lesquels la dynamique des variations spatiales de niveaux de gris - pour le fond et pour l'objet - reste petite par rapport au bruit de capture.

$$(a) \quad \Pr[\hat{o}_t(s) = 1 / \Psi_A = 0] = \frac{2}{\sqrt{2\pi\sigma_y^2}} \int_{\theta}^{+\infty} e^{-\frac{x^2}{2\sigma_y^2}} dx,$$

avec $\sigma_y^2 = 2.\sigma^2$, correspondant à la variance de la différence $y=I(t,s)-I(t-1,s)$.

- Pour une transition *objet-fond* ou *fond-objet* ($\Psi_A = 1$), l'observation $\hat{o}(s,t)=CCT(s,t)$ devrait être *non nulle*. La probabilité qu'il en soit autrement vaut (voir fig.IV.9) :

$$(b) \quad \Pr(\hat{o}_t(s) = 0 / \Psi_A = 1) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \int_{-\theta}^{+\theta} e^{-\frac{(x-M)^2}{2\sigma_y^2}} dx,$$

avec $M=|m_o-m_f|$.

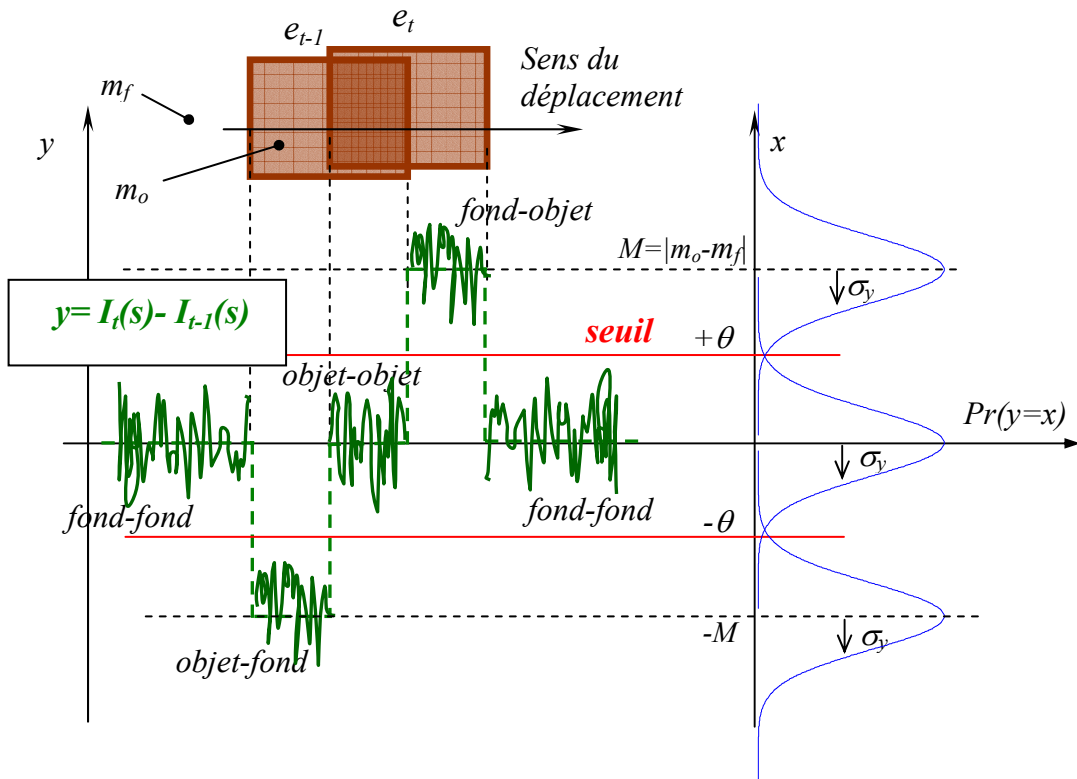


Fig.IV.9 : Interprétation de la relation entre le bruit gaussien de l'image et le seuil de binarisation θ du modèle.

Pour pouvoir utiliser le formalisme du modèle d'observation avec bruit de canal, il faut choisir le seuil de binarisation θ tel que les deux probabilités (a) et (b) soient égales⁵¹, ce qui s'écrit:

$$(a) = (b) \Leftrightarrow \text{erfc}_{\sigma_y}(\theta) = \frac{1}{2} \left\{ \text{erfc}_{\sigma_y}(M - \theta) - \text{erfc}_{\sigma_y}(M + \theta) \right\},$$

⁵¹ si la variance du bruit est faible, alors une bonne approximation pour le seuil est évidemment $\theta=M/2$.

où $erfc$ est la fonction d'erreur définie par :

$$erfc_{\sigma_y}(x) = \frac{1}{\sqrt{2\pi}\sigma_y} \int_x^{+\infty} e^{-\frac{t^2}{2\sigma_y^2}} dt = erfc_1\left(\frac{x}{\sqrt{2}\sigma_y}\right).$$

Si l'on respecte ce choix pour le seuil de binarisation, alors on peut définir le taux d'erreur ε d'un bruit de canal N entre l'observation binaire et le champ d'étiquettes selon :

$$\Pr(N = 1) = \frac{\varepsilon}{2} = \Pr(\hat{\delta}_i(s) = 1 / \Psi_A = 0) = \Pr(\hat{\delta}_i(s) = 0 / \Psi_A = 1), \text{ et bien sûr :}$$

$$\Pr(N = 0) = \frac{1-\varepsilon}{2} = \Pr(\hat{\delta}_i(s) = 0 / \Psi_A = 0) = \Pr(\hat{\delta}_i(s) = 1 / \Psi_A = 1).$$

Le taux d'erreur ε est fonction de la variance du bruit gaussien et du seuil de binarisation :

$$\varepsilon = erfc_{\sqrt{2}\sigma}(\theta) = \frac{2}{\sqrt{\pi}\sigma} \int_{\theta}^{+\infty} e^{-\frac{t^2}{\sigma^2}} dt$$

La fig.IV.10 montre le résultat de la résolution numérique pour θ de l'équation (a)=(b), et le taux d'erreur de canal correspondant.




Fig.IV.10 : A gauche, seuil de binarisation optimal en fonction de la différence entre les niveaux de gris du fond et de l'objet, pour plusieurs variances du bruit de capture. A droite, taux d'erreur de canal correspondant pour le modèle d'observation.

Energie de rappel aux données. En notant $\beta_c = \ln\left(\frac{1-\varepsilon}{\varepsilon}\right)$, on peut exprimer la statistique du bruit de canal de façon condensée selon (cf. exemple Chap.I,§6.1) :

$$\Pr(N = n) = \frac{\varepsilon}{2} \exp(\beta_c \cdot \delta(n)), \text{ avec } \delta(0)=1 \text{ et } 0 \text{ sinon.}$$

Le terme de vraisemblance marginal s'exprime alors par :

$$\Pr[\hat{O}_t(s) = \hat{o}_t(s) / E_t(s) = e_t(s), E_{t-1}(s) = e_{t-1}(s)] = \frac{\varepsilon}{2} \exp[\beta_C \cdot \delta(\hat{o}_t(s) - \Psi_A(e_t(s), e_{t-1}(s)))],$$

d'où la vraisemblance de l'observation binaire \hat{O}_t (si toutefois on considère les bruits de canal indépendants entre les pixel de l'image) :

$$\Pr(\hat{O}_t = \hat{o}_t / E_t = e_t, E_{t-1} = e_{t-1}) = \left(\frac{\varepsilon}{2}\right)^{n \times m} \exp\left[\beta_C \sum_{s \in S} \delta(\hat{o}_t(s) - \Psi_A(e_t(s), e_{t-1}(s)))\right]$$

($n \times m$ est le nombre de pixels de l'image). L'énergie d'attache aux données est finalement :

$$U_{obs}(e_t / \hat{o}_t, e_{t-1}) = \sum_{s \in S} V_C[\hat{o}_t(s), e_t(s), e_{t-1}(s)] \text{ où le potentiel des "cliques" } V_C \text{ vaut :}$$

$$V_C(e_t(s), \hat{o}_t(s), e_{t-1}(s)) = -\beta_C \delta[\hat{o}_t(s) - \Psi_A(e_t(s), e_{t-1}(s))].$$

Soit, à une constante additive près, et en utilisant la définition de Ψ_A :

$$U_{obs}(e_t / \hat{o}_t, e_{t-1}) = -\frac{\beta_C}{2} \sum_{s \in S} (2e_{t-1}(s) - 1)(2\hat{o}_t(s) - 1)$$

On remarquera que e_{t-1} et \hat{o}_t sont des champs de contrainte, *fixes* pendant l'optimisation du champ d'étiquettes courant e_t . La force de contrainte ou rappel aux données locales est calculés selon :

$$F_c(s, t) = -\{V_c[e_t(s) = 1, \hat{o}_t(s), e_{t-1}(s)] - V_c[e_t(s) = 0, \hat{o}_t(s), e_{t-1}(s)]\},$$

soit :
$$F_c(s, t) = -\beta_c (2e_{t-1}(s) - 1)(2\hat{o}_t(s) - 1)$$

On retrouve bien l'esprit de la définition de la fonction Ψ_L de Lalande, à savoir que l'on *préfère changer l'état de mouvement seulement quand un changement important est détecté* ; autrement, on préfère garder l'état de mouvement passé (effet mémoire).

Les séquences étudiées par Dumontier et Caplier, correspondent à $M \approx 220 - 180 = 40$ et $\sigma \approx 10$; notre modèle conduit alors à $\theta = 21,5$. Par *analogie* avec la forme de la force de rappel locale (voir fig.IV.11)⁵², on devrait avoir $\theta = \alpha/2$, soit $\alpha = 43$. Caplier [Caplier95] préconise $\alpha = 20$ pour toutes les séquences, tout en remarquant que la valeur du paramètre n'affecte pas beaucoup le résultat final de la détection.

⁵² l'analogie ne concerne pas la *valeur* de la force, seulement est comparé le seuil qui dicte la tendance - positive ou négative - pour fixer à +1 l'étiquette à l'instant suivant.




Fig.IV.11 : Force de rappel à l'observation discrète (dans le cas $e_{t-1}=0$) et correspondance entre le seuil de binarisation θ du nouveau modèle et le paramètre α du modèle d'observation continu de Dumontier (voir aussi fig.IV.7).

6.2.2 Champ d'étiquettes et voisinage

La fig.IV.12 représente le système de voisinage choisi pour notre modèle. Le voisinage spatial peut être d'ordre un ou deux. Les "cliques futures" du modèle de Dumontier reliant l'observation discrète $\hat{o}(s,t+1)$ et le champ d'étiquettes courant $e(s,t)$ ont été éliminées. Il reste que l'on peut choisir de garder ou non la contrainte temporelle vers le passé car la définition du potentiel Ψ_A réalise déjà une fonction mémoire. Cependant celle-ci est *conditionnelle* : le lien vers le passé est coupé dès que $o(s,t)$ dépasse le seuil θ . C'est ainsi que deux modèles *différents* sont envisageables, avec ou sans terme de *rémanence*.

(A) Modèle avec terme de rémanence

Dans ce modèle, la liaison vers le passé est inconditionnelle (elle ne dépend pas de l'observation). Le terme F_P provenait dans le modèle de Lalande de la *régularisation* temporelle du champ ; il n'est ici qu'une *contrainte* temporelle utile pour limiter le bruit. La force locale s'écrit :

$$F(s,t) = F_S(s,t) + F_P(s,t) + F_C(s,t), \text{ soit :}$$

$$F(s,t) = \beta_S \sum_{r \in V(s)} (2.e_t(r) - 1) + \beta_P (2.e_{t-1}(s) - 1) - \beta_C (2.e_{t-1}(s) - 1)(2.\hat{o}_t(s) - 1)$$




Fig.IV.12 : cliques spatiales et champs de contrainte pour le modèle avec rémanence (a) et sans rémanence (b) (comparer avec le système de voisinage du modèle de Dumontier de la fig.IV.6) .

(B) Modèle sans terme de rémanence.

Dans ce modèle on considère suffisante la régularisation *spatiale* pour l'élimination du bruit. Ainsi, aucun terme de la force locale n'opère de façon antagoniste. La force locale s'écrit tout simplement :

$$F(s,t) = F_s(s,t) + F_o(s,t), \text{ soit:}$$

$$F(s,t) = \beta_s \sum_{r \in V(s)} (2.e_t(r) - 1) - \beta_c (2.e_{t-1}(s) - 1)(2.\hat{o}_t(s) - 1)$$

Commentaires. L'idée "si un pixel était en mouvement, on préfère qu'il reste en mouvement, et s'il était fixe, qu'il reste fixe" (effet mémoire), ne s'appliquera *que* pour les pixels pour lesquels il n'y a *pas eu de changement temporel significatif*. C'est désormais le modèle d'observation, à lui seul, qui prend en compte le bruit : s'il y a un *faux* changement temporel (dû au bruit), il sera sans doute local, et la régularisation spatiale se chargera de le corriger (voir illustration du principe dans la fig.IV.13 ci-dessous).

Le modèle (B) a toutes les bonnes propriétés annoncés en introduction (§6.1). Tout d'abord, l'origine des termes est clair, et les paramètres (θ , β_o , et β_s) peuvent être déduits, sinon de façon automatique⁵³, au moins de façon systématique et rationnelle à

⁵³ Le paramètre β_s caractérise le champ de Markov d'étiquettes final, c.à.d. le MB (masque binaire des objets mobiles). L'ajustement de ce paramètre dépend donc des caractéristiques des objets en mouvement dans la scène ; dans les cas simples étudiés (cf. Ann.C), le MB idéal est constitué à chaque instant d'une

partir des caractéristiques de la séquence d'images. On remarquera aussi que le modèle n'omet aucune des tâches nécessaires à la régularisation de la CCT (§4.2.2), et cela sans qu'il y ait de contradiction fonctionnelle entre les termes de la force locale :

- Opérations (a) et (c) : l'opération de remplissage de la zone de glissement et d'élimination du bruit sont réalisées grâce au terme de régularisation spatiale F_S ;
- Opérations (b) et (c) : l'élimination de la zone d'écho et l'intégration de la zone de recouvrement se font grâce au terme de rappel conditionnel F_C .

Enfin, les valeurs de la force locale sont *discrètes*, ce qui permettra de simplifier la conception d'un prototype optoélectronique utilisant des modulateurs spatiaux de lumière *binaires* (voir chapitre suivant). C'est donc le modèle retenu pour le démonstrateur optoélectronique qui sera exposé au chapitre suivant.

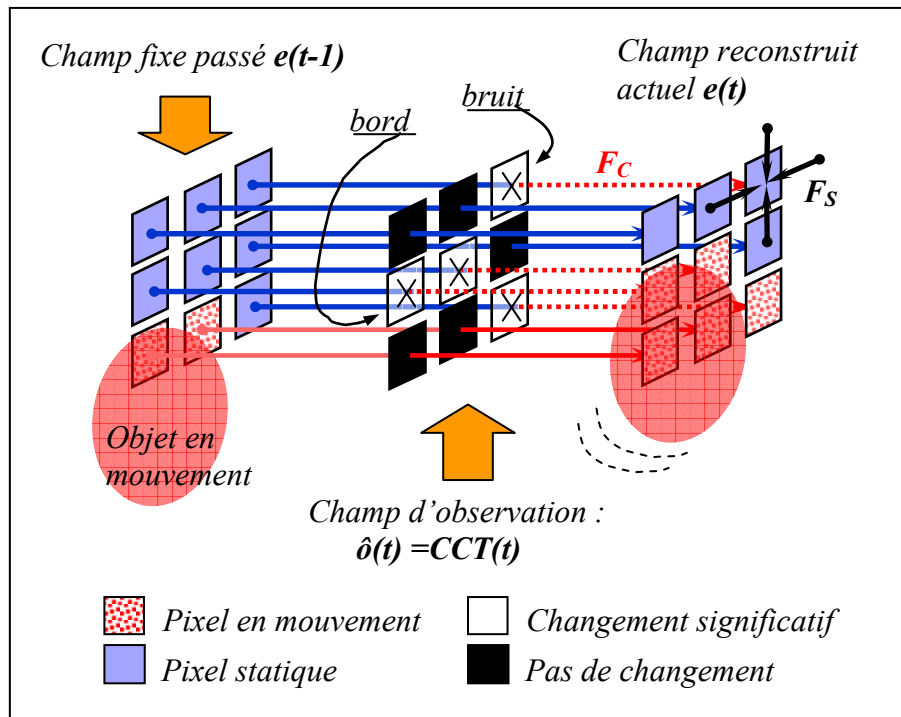


Fig.IV.13 : philosophie de l'algorithme de détection du mouvement proposé. La force spatiale de régularisation (F_S) prend en charge le traitement immédiat du bruit de la carte des changements temporels.

Notons une particularité du modèle (plus ou moins partagé par les modèles de Lalande et Dumontier) : si un objet présent dans la scène mais jusque là immobile commence à se

forme plus ou moins connexe sur fond immobile. Ce genre de cartes binaires n'est pas sans rappeler le résultat de la restauration d'images binaires bruitées étudié au Chap.I et II, pour lesquelles on avait $\lambda = \beta_S / \beta_O$ entre 0,4 et 1,2 ; en première approximation on aura alors β_S / β_C compris entre ces deux valeurs, mais une estimation plus précise est théoriquement possible (voir Chap.I, §5.1.2).

déplacer, alors il est facile de voir que la trace initiale de l'objet immobile ne pourra pas disparaître par la suite du champ d'étiquettes ; de même si un objet auparavant en mouvement s'immobilise tout à coup (et reste présent dans la scène), son masque final (avant qu'il ne s'immobilise) ne disparaît pas non plus. Il s'agit du même problème que peuvent rencontrer des méthodes de détection du mouvement basées sur la mise à jour d'une image de référence (§4.1). En fait, dans un certain nombre de cas ceci n'est pas un inconvénient, soit parce que l'objet mobile rentre et ressort de la scène—cas des voitures dans une route surveillée par une caméra fixe—, soit parce que précisément il peut s'avérer utile de garder la trace des objet mobiles *en puissance*.

Remarque : L'énergie totale à minimiser pour le modèle proposé est finalement :

$$U(e_t / e_{t-1}, \hat{o}_t) = U_{contr}(e_t / e_{t-1}, \hat{o}_t) + U_{reg}(e_t), \text{ où}$$

$$\begin{cases} U_{reg}(e_t) = -\frac{\beta_S}{2} \sum_{s \in S} \sum_{r \in V(s)} (2.e_t(s) - 1)(2.e_t(r) - 1), \text{ (régularisation spatiale).} \\ U_{contr}(e_t / e_{t-1}, \hat{o}_t) = +\beta_C \sum_{s \in S} (2.e_{t-1}(s) - 1)(2.\hat{o}_t(s) - 1)(2.e_t(s) - 1) \\ = -\beta_C \sum_{s \in S} (2.b(s) - 1)(2.e_t(s) - 1), \text{ (terme de contrainte).} \end{cases}$$

Nous avons posé dans la formule ci-dessus : $b(s) = [e(s, t-1) \text{ xor } \hat{o}(s, t)]$ ("xor" représente le *OU exclusif* logique). On a bien sûr $e(t-1) = MB(t-1)$ et $\hat{o}(t) = CCT(t)$. Le champ binaire b est donc le résultat d'un traitement binaire très simple sur les champs $MB(t-1)$ et $CCT(t)$. Si l'on laisse de côté le terme de lissage spatial, le minimum énergétique est tout simplement réalisé quand $e(t) = b(t)$; autrement dit, en absence de bruit un procédé simple pour obtenir le masque binaire des objets mobiles consiste à réaliser itérativement l'opération booléenne : $MB(t) = [MB(t-1) \text{ xor } CCT(t)]$, avec $MB(0)$ initialisé à 0.

6.2.3 Méthode d'optimisation

La méthode d'optimisation choisie est bien sûr le *recuit simulé* étudié en détail au Chap.II. Le principal avantage est qu'il n'y a pas à se préoccuper de la "propreté" de l'initialisation du champ d'étiquettes avant de lancer la procédure d'optimisation, car l'algorithme converge vers un minimum global de la fonction d'énergie indépendamment de la configuration initiale. Par contre, la charge de calcul est bien plus importante que pour n'importe laquelle des méthodes déterministes, mais c'est précisément le rôle du PPOS étudié au Chap.III que de rendre le calcul d'optimisation possible même à cadence vidéo. La *fig.IV.14* donne un schéma synoptique de l'algorithme proposé.

Il est intéressant de noter l'analogie entre la force locale correspondant au modèle de débruitage d'images binaires (*cf.* Chap.I, §5.1) et celle correspondant au modèle de détection :

- Détection de mouvement : $F(s, t) = \beta_S \sum_{r \in V(s)} (2.e_t(r) - 1) + \beta_C \cdot (2.b(s) - 1)$
- Restauration d'images binaires : $F(s, t) = \beta_S \sum_{r \in V(s)} (2.e(r) - 1) + \beta_o \cdot (2.o(s) - 1)$

La recherche du MB à chaque instant correspond donc au débruitage d'une "image" binaire : le champ $b(t)=[MB(t-1) \text{ xor } CCT(t)]$. Les paramètres du *recuit* seront donc les mêmes pour le débruitage et pour la détection du mouvement. En particulier, on pourra utiliser le concept de *recuit sérieux* pour évaluer les performances du démonstrateur final.

Il est important de noter que la remarque faite au Chap.II.§3.2 à propos de la méthode de débruitage s'applique ici en toute rigueur : il se peut en effet que le résultat du débruitage du champ binaire $b(t)$ soit "meilleur" (au sens de la conservation des discontinuités) pour une méthode d'optimisation déterministe *bien initialisée* que pour l'algorithme stochastique de recuit simulé. L'effet sera d'autant plus évident que les dimensions de l'image traitée resteront modestes (c'est le cas pour les imagerie 24x24 du démonstrateur optoélectronique). La prise en compte des discontinuités dans le modèle de débruitage rendrait sûrement meilleure la qualité du traitement stochastique par rapport aux méthodes déterministes. D'ailleurs, comme expliqué au §4.3, plusieurs techniques de détection du mouvement ont été proposées qui tirent avantage d'une détection conjointe des contours.

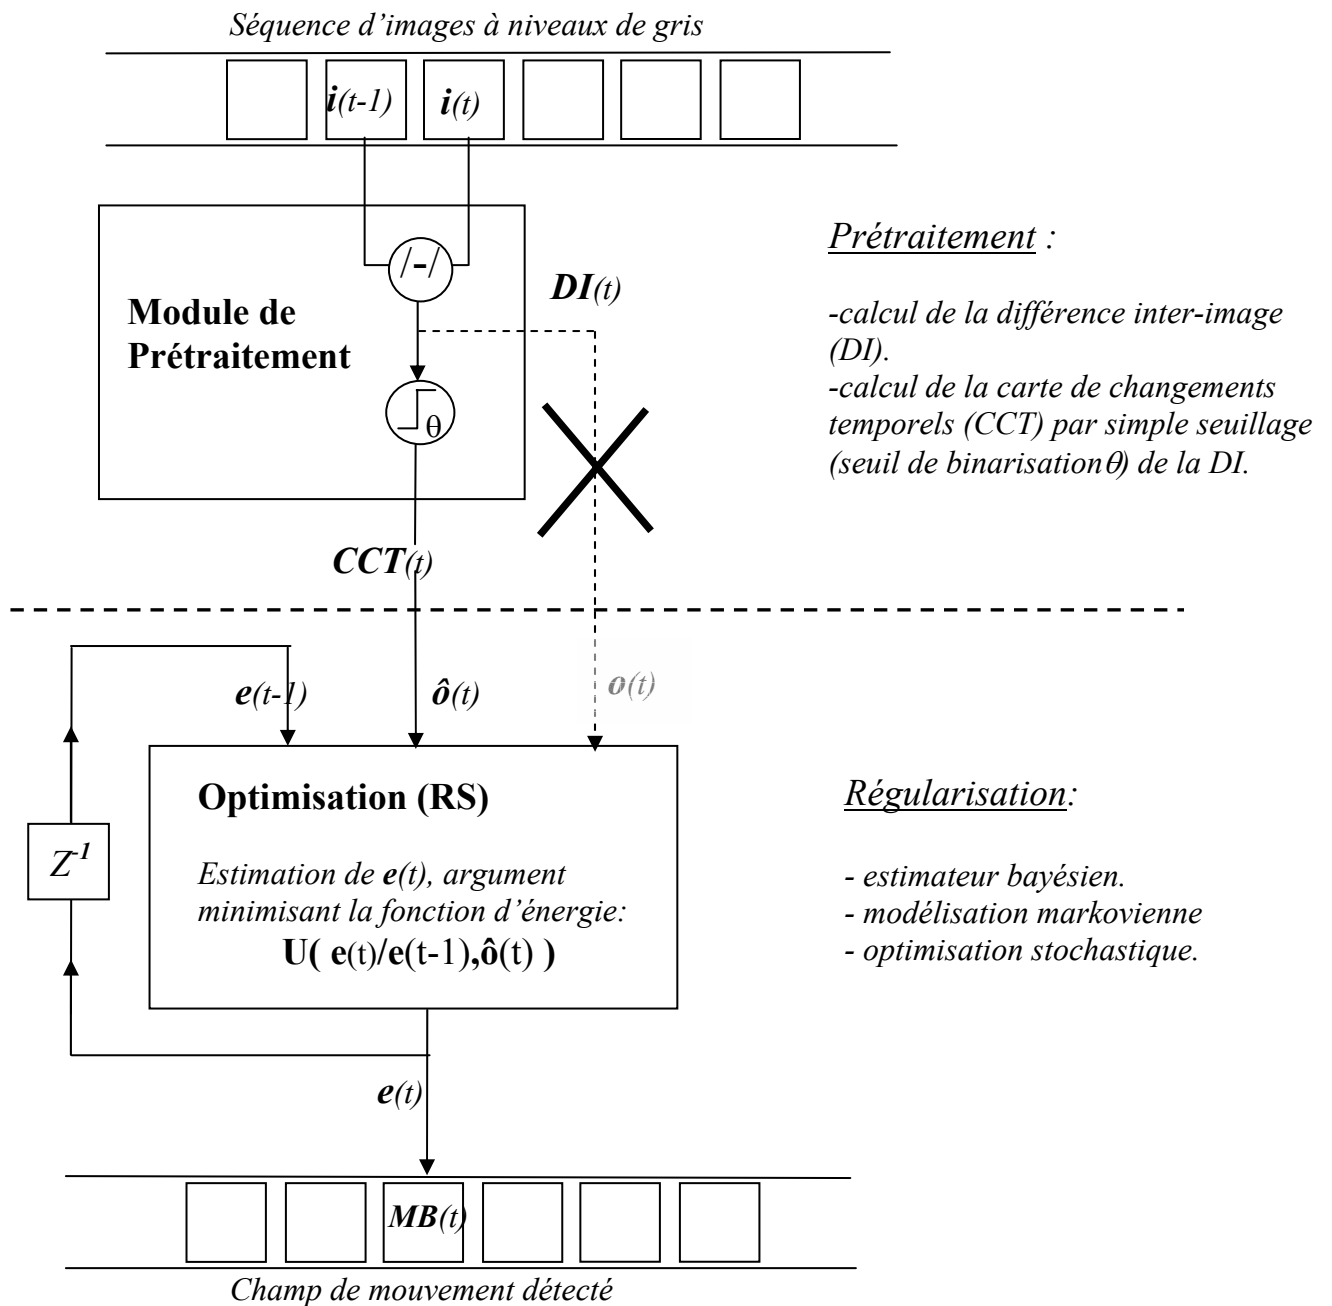


Fig.IV.14 : Schéma synoptique de l'algorithme final de détection du mouvement.

Le prétraitement se résume au calcul de la CCT par simple seuillage de la différence inter-image (DI) ; celle-ci n'est pas utilisée comme champ de contrainte à l'observation. Le calcul du masque des objets mobiles MB est réalisé par estimation bayésienne et optimisation stochastique (et parallèle) -voir Chap.II ; il n'est donc pas nécessaire d'initialiser 'proprement' le champ d'étiquettes.

Le module d'optimisation sera implanté matériellement grâce au processeur PPOS étudié au Chap.III. Pour simplifier la réalisation optoélectronique (modulateurs de lumière binaires rapides) les champs de contrainte aux données $e(t-1)$ et $\hat{o}(t)$ sont binaires.

7. Simulation et performances

7.1 Qualité du masque des objets mobiles MB.

Nous avons cherché à valider l'algorithme de détection du mouvement proposé sur quelques séquences réelles et synthétiques. On trouvera une description détaillée des séquences dans l'Annexe C ; on se limitera ici à commenter quelques résultats.

7.1.1 Séquences synthétiques.

Nous avons exploré rapidement l'influence du *bruit* du capteur, du *contraste* (entre l'objet mobile et le fond), de la *taille* de l'objet mobile et de la *vitesse* de celui-ci, et enfin l'incidence de la *forme* sur la qualité du masque des objets mobiles, et cela pour le modèle proposé et pour le modèle de Dumontier-Caplier.

Contraste et bruit : (voir en particulier les séquences *Contraste_1* et *Contraste_2* de l'Ann.C). Le taux d'erreur de canal ε est représentatif du rapport signal sur bruit du champ binaire d'*observation* (la CCT) -voir §6.2.1. Il dépend du contraste entre l'objet mobile et le fond, et aussi du bruit du capteur (supposé gaussien). La différence entre les niveaux de gris entre l'objet et le fond est de l'ordre de 20 unités pour les séquences étudiées ; la variance du bruit du capteur vaut $\sigma = 10$ (ces ordres de grandeur correspondent aux niveaux de gris rencontrés dans les séquences "réelles" -cf Annexe C). Dans ces conditions, le seuil de binarisation vaut $\theta \approx 12$ et la CCT à un taux de bruit de canal $\varepsilon \approx 23\%$; le terme de contrainte est proche de l'unité $\beta_C = 1,27$ (cf. §6.2.1).

On constate que pour des séquences "bien conditionnées" par rapport aux hypothèses du modèle (i.e. objet et fond sont uniformes, §3.2), le modèle discret proposé se comporte mieux que le modèle continu de Dumontier-Caplier. En particulier la zone de glissement est correctement reconstruite, ce qui n'est pas bien réalisé par le modèle continu. Ceci est dû au fait que ni l'observation continue $o(t) = DI(t)$ ni l'observation binaire $\hat{o}(t) = CCT(t)$ ne présentent de signal significatif sur le fond et sur la zone de glissement. Chose qui peut paraître paradoxale, les performances du modèle de Dumontier-Caplier s'améliorent un peu quand le rapport signal sur bruit *diminue* (le bruit augmente et/ou le contraste diminue), car des détections parasites apparaissent dans le "vide" de signal laissé dans la zone de glissement, détections qui permettent parfois une amorce de reconstruction -qui sera perpétuée par la suite grâce au terme de rappel temporel. Cette remarque tient aussi pour le reste des séquences étudiées (voir en particulier les séquences *Automobile* avec et sans bruit).

Taille : Une rétine capable de détecter le mouvement en temps-réel pourrait trouver des applications dans le domaine du contrôle routier. Une caméra munie d'un tel capteur pourrait par exemple être placée à la hauteur d'un sémaphore et être dirigée vers un carrefour ; dans ces conditions, il n'est pas absurde d'imaginer un champ de vision d'à peu près dix mètres de large pour la caméra de surveillance. Imaginons un capteur de

128x128 pixels, ayant à une surface d'environ un centimètre carré. Le grandissement du système optique pour couvrir la largeur du champ doit être de $1\text{cm}/10\text{m}=10^{-3}$. Une voiture mesure environ 3m de long sur 1,5 de large, et donne alors une image sur la rétine d'à peu près 20x10 pixels. Les niveaux de gris et le bruit des séquences étudiées sont ici les mêmes que pour la séquence *Contraste_1*.

Pour des objets petits (de l'ordre de deux fois la taille du voisinage, voir séquence *Taille_1*), les deux algorithmes se comportent relativement bien. Pour des tailles supérieures (de l'ordre de 20x10 pixels - voir *Taille_2* et séquences *Automobile*), seul l'algorithme proposé arrive à reconstruire correctement la zone de glissement.

Vitesse : Il n'est pas absurde de supposer que les voitures ont, dans le carrefour, des vitesses comprises entre 10 et 60km/h. Les vitesses des images mobiles sur la rétine sont comprises alors entre 1 et 10 pixels/s. La zone de recouvrement correspond à 3% et 20% de l'objet mobile respectivement (voir séquences *Taille*, *Contraste* et séquences réelles). La séquence *Vitesse* représente la situation particulière dans laquelle il *n'y a pas de zone de glissement*, car l'objet se déplace trop vite entre deux séquences consécutives. On constate un comportement particulier pour l'algorithme de Dumontier-Caplier (le masque de l'objet est accompagné de deux "copies" -passé et futur). Notre modèle souffre d'un autre défaut, à savoir, l'incapacité à éliminer la trace initiale de la zone d'écho (voir séquences). Un phénomène similaire peut avoir lieu si le signal fourni par la différence inter-image sur la zone d'écho est en dessous du seuil de binarisation (par exemple pour un objet dont le niveau de gris ne soit pas uniforme mais évolue spatialement). C'est ce qui arrive dans la séquence *Automobile_1* (les roues de la voiture semblent se "multiplier").

Forme : Le choix de la structure du voisinage markovien doit en principe être fait en fonction des caractéristiques spatiales de l'image (et les caractéristiques du mouvement). Ainsi, un voisinage d'ordre 1 favorise les angles droits et les mouvements parallèles aux axes de la grille ; un voisinage d'ordre 2 favorise les coins arrondis et les mouvements souples. Le modèle de Dumontier-Caplier testé utilise exclusivement un voisinage d'ordre 2. Nous avons testé notre modèle en choisissant un voisinage d'ordre 1, c'est pourquoi les masques reconstruits sur les séquences correspondant à des rectangles en mouvement sont plus fidèles à la forme de l'objet pour notre modèle (voir notamment la séquence *Croisement*). La séquence *Disque* montre l'amélioration du rendu des arrondis grâce au voisinage d'ordre 2.

7.1.2 Séquences réelles

Nous avons cherché à valider le modèle sur quelques scènes de rue, prises grâce à une caméra de vidéoconférence pour PC (QuickCam™). Les conditions naturelles d'éclairage, de contraste, de bruit, etc., ne sont pas contrôlées ni estimées automatiquement (il faut garder à l'esprit qu'il s'agit juste d'une démonstration). Les séquences présentent un bruit relativement faible ; par contre une grande quantité de

facteurs parasites (variations d'éclairage locales, "motifs" internes à l'objet mobile, dégradé du niveaux de gris sur les surfaces) écartent le problème des hypothèses faites au §3.2. Sur ces séquences l'algorithme de Dumontier-Caplier semble plus performant, au moins pour ce qui est de la localisation grossière de la région en mouvement (voir notamment la séquence *Couloir*).

7.1.3 Conclusion.

L'observation des séquences réelles et synthétiques laisse apparaître une certaine *complémentarité* dans les modèles. Tout d'abord, le modèle de Dumontier-Caplier semble s'attaquer directement à la régularisation spatiale de la carte de changements temporels (il est aisé de remarquer que le masque des objets mobiles ressemble beaucoup à une simple version débruitée de la *CCT*). Le principal défaut du modèle, comme on pouvait s'y attendre d'après l'analyse faite au §5.7, est que les régions régulières et uniformes de l'objet en mouvement ne peuvent pas être détectées correctement. Cela tient au choix de la fonction d'observation Ψ_D (cf.§5.5), dont le principe est de ne considérer en mouvement que les régions présentant une forte variation d'intensité (supérieure au seuil α). Par contre, le modèle se comporte mieux face aux situations mal conditionnées par rapport aux hypothèses définies au §3.2 (détails trop fins et/ou mouvement trop rapide de l'objet mobile ne permettant pas de définir correctement les quatre zones de la *CCT* - fond, zone de glissement, zone d'écho et zone recouvrement). C'est le cas pour des objets texturés et/ou à niveaux de gris variable dans le temps (changements d'éclairage locaux dus par exemple à la variation de l'inclinaison des surfaces), mais aussi pour des objets mobiles dont la *forme* évolue dans le temps (dans ce dernier cas le masque reconstruit indique bien la *région* mobile, mais avec une perte substantielle de la *forme* de l'objet mobile). C'est bien sûr le cas pour les séquences réelles étudiées (cf. Ann.C, séquences *Piétons* et *Couloir* notamment).

Quant au modèle proposé, on remarquera la forte ressemblance entre le masque final et le champ binaire noté $XOR(t)$ dans l'Ann.C, issu de l'opération itérative : $XOR(t)=[XOR(t-1) \text{ xor } CCT(t)]$. La ressemblance est d'autant plus grande que le bruit est faible (comparer séquences réelles avec et sans ajout de bruit). En absence de bruit, le champ XOR est en toute rigueur équivalent au MB , mais en présence de bruit, le champ XOR s'écarte de plus en plus du masque binaire MB , car le bruit s'accumule irrémédiablement. Autrement dit, le masque binaire des objets mobiles *n'est pas* une simple version débruitée du champ XOR - ceci est vrai pour $t=0$, mais l'avantage de la restauration se fait sentir de plus en plus fortement au fur et à mesure du déroulement de la séquence.

Ceci nous conduit à une remarque d'ordre général : il y a deux situations dans lesquelles la détection du mouvement est possible sans avoir recours à une image de référence ou à des techniques plus élaborées (reconnaissance des formes, suivi de cibles par corrélation, etc.) :

a) La première correspond à la situation dans laquelle l'objet mobile possède des textures fines et/ou des motifs intérieurs constants⁵⁴, et le fond (uniforme ou également texturé) à *le même niveau de gris moyen* que l'objet (la séquence est *totale*ment mal conditionnée par rapport aux hypothèses du §3.2). Dans ce cas, le débruitage de la carte de changements temporels fournit une approximation suffisamment bonne du masque binaire des objets mobiles, tandis que la méthode de reconstruction basée sur l'intégration de la zone de recouvrement et l'élimination de la zone d'écho s'avère inefficace (puisque le "saut" de l'objet mobile entre deux images consécutives est plus grand que la "taille" de la texture, et la CCT ne fournit pas les quatre zones décrites au §4.2.2). C'est par exemple le cas de la séquence mal conditionnée *Couloir* dans l'Ann.C.

b) La deuxième situation correspond au cas où objet et fond sont uniformes, mais possèdent *des niveaux de gris moyens différents* (autrement il serait impossible d'effectuer une quelconque détection). La séquence est "parfaitement conditionnée" par rapport aux hypothèses du §3.2. Dans ce cas, la CCT seule n'est pas une bonne approximation du MB (impossibilité de récupérer la zone de glissement), et la reconstruction du masque des objets mobiles en utilisant la stratégie basée sur l'intégration de la zone de recouvrement et l'élimination de la zone d'écho est justifiée. Cependant, dans une situation de type b) "pure", on peut se demander s'il ne serait plus simple de retrouver le MB en effectuant un simple seuillage de l'image permettant de dégager l'objet du fond et en régularisant ensuite le résultat obtenu pour en éliminer le bruit.

En fait, une situation *réelle* pour laquelle on ne connaît pas a priori les caractéristiques de l'image (niveaux de gris de l'objet et du fond, taille des textures, etc.) correspond à des séquences mal conditionnées par rapport aux hypothèses du §3.2, dont les caractéristiques évoluent dans le temps entre les situations a) et b), (à cause des variations d'éclairage et/ou la déformation de l'objet mobile, etc.). Les séquences réelles seront "plutôt de type a)" ou "plutôt de type b)".

Dans une situation "plutôt de type a)", la méthode de détection simple consistant à débruiter la CCT se verra considérablement améliorée si l'on rajoute des informations permettant de reconstruire la zone de glissement ; une stratégie pour le faire est proposé dans [Bellon94] consistant à prendre en compte à la fois la CCT et des informations provenant d'une image de référence. L'utilisation conjointe de ces deux champs d'observation (de nature très différente) permet selon l'auteur de mieux gérer les zones de glissement.

Dans une situation "plutôt de type b)" il est tout d'abord vraisemblable (mais on ne l'a pas testé) que la méthode basée sur le traitement spatio-temporel à partir de la CCT soit plus

⁵⁴ "texture fine et/ou motif intérieur constant" doit être compris ici au sens de "détails pour lequel la CCT ne permet pas d'obtenir l'ensemble des quatre zones définies au §3.2, compte tenu de la vitesse de l'objet, la fréquence de capture d'images et la résolution du capteur" (voir note bas de page 5 au §3.2).

robuste face aux aléas dus au mauvais conditionnement de la séquence qu'un simple seuillage suivi d'une régularisation spatiale, et cela grâce à l'effet "mémoire" propre à la contrainte temporelle. Par ailleurs, la méthode de détection se verra sans doute améliorée si l'on rajoute des informations permettant de "rattraper" les erreurs produits par le mauvais conditionnement de la séquence ; pour ce faire, une stratégie peut consister - comme c'est le cas dans le modèle de Lalande - à analyser le champ d'observation continu $o(t)$ grâce à deux seuils m_1 et m_2 (tab.IV.1 au §5.4.1) au lieu d'un seul (paramètre θ de binarisation), ce qui permet de distinguer les transitions fond-objet (ou objet-fond) et les transition fond-fond (ou objet-objet) ; l'idée subsiste (simplifiée) dans le modèle de Dumontier, car si l'observation continue $o(t)$ dépasse le seuil α (voir §5.5), le site sera "encouragé" par le terme de contrainte à prendre l'état de mouvement, quel qu'eut été l'état de mouvement passé (voir fig.IV.7 et commentaire au §5.5.1).

Remarque : Si l'éclairage est constant, il est toujours possible de ramener une situation de type a) ("mal conditionnée par rapport aux hypothèses du §3.2") à une situation de type b) ("bien conditionnée") en augmentant la résolution du capteur et/ou sa fréquence de capture.

Une remarque pour finir : le modèle de Dumontier-Caplier a été testé en utilisant un algorithme d'optimisation déterministe (*ICM*). La minimisation de la fonction d'énergie du modèle est donc plus ou moins bien approchée (et il n'y a pas de moyen évident de mesurer le biais que cela introduit dans le résultat final de la détection). La comparaison des modèles devrait se faire en utilisant un algorithme d'optimisation performant de type recuit simulé - en temps différé bien sûr. Le modèle de Dumontier-Caplier a été testé par les auteurs en utilisant des techniques déterministes, et l'algorithme final prescrit également la façon d'initialiser le champ d'étiquettes (au moyen de la $CCT(t+1)$, voir fig.IV.8).

7.2 Charge de calcul.

Nous n'avons pas réalisé des véritables recuits sérieux (1000 itérations) sur les séquences de test ; nous avons préféré optimiser de façon heuristique le nombre d'itérations du recuit, qui s'élève finalement à une *centaine* par image. La méthode de Dumontier-Caplier utilise une technique de relaxation déterministe (*ICM*) comportant entre 4 et 5 itérations par image. Finalement, la charge de calcul correspondant au traitement du problème de la détection du mouvement par recuit simulé est quelque 20 fois plus grande que pour une technique basée sur une méthode déterministe (en tout cas pour des images de l'ordre de 100x100 pixels). On pourra comparer au tab.VI.1 du ChapVI,§3.2 les performances respectives de plusieurs réalisations matérielles conçues pour traiter le problème de la détection du mouvement par régularisation markovienne ;

on verra alors que seul un processeur exploitant l'approche du *parallélisme massif* peut aujourd'hui prétendre rendre compte de cette énorme charge de calcul en *temps réel*.

8. Conclusion

Au Chap.III nous avons présenté un prototype de processeur optoélectronique capable de simuler le comportement d'un réseau bidimensionnel de spins (modèle d'Ising 2D). Moyennant un montage optique adéquat, on peut utiliser ce prototype pour traiter le problème du débruitage d'images binaires, et donc à l'occasion le problème de la détection du mouvement (*cf* §6.3). Au chapitre suivant nous allons donc aborder la conception et la réalisation d'un tel montage optoélectronique. L'application visée est bien sûr la détection du mouvement à cadence vidéo (sur des images 24x24, n'oublions toujours pas qu'il s'agit d'un démonstrateur), mais le montage servira aussi pour étudier d'autres aspects fondamentaux des montages optoélectroniques, à savoir les *interconnexions optiques en espace libre*.

Chapitre V

Un démonstrateur utilisant le PPOS pour la détection du mouvement.

1. Introduction

On s'intéressera dans ce chapitre à la conception, réalisation et test d'un prototype optoélectronique complet pour le traitement d'images par *régularisation bayésienne et modélisation markovienne* (cf. Chap.I) dont le noyau est le *processeur parallèle stochastique optoélectronique SPIE600* (cf. Chap.III), chargé du calcul d'optimisation par *recuit simulé parallèle* (cf. Chap.II). Le démonstrateur comprend entre autres deux modulateurs de lumière ferroélectriques sur circuit intégré (cf. Ann.A) et un réseau de Dammann (cf. Ann.B) pour réaliser des *interconnexions optiques en espace libre*. Cette première version du démonstrateur est réalisée grâce à des éléments d'imagerie macro-optiques.

Le but final étant d'évaluer la capacité du PPOS à intégrer une chaîne de traitement d'images temps-réel (cadence vidéo), on s'est intéressé naturellement au problème de la *détection du mouvement* (cf. Chap.IV). Toutefois, tous les traitements bas niveau *spatiaux* décrits au Chap.I,§5 (restauration d'images binaires et B-codage d'images) peuvent en principe être abordés et démontrés à cadence vidéo sur le prototype.

1.1 Principe de fonctionnement.

L'architecture optique doit reproduire le schéma algorithmique donné à la fin du Chap.IV (*fig.IV.14*). La chaîne de traitement comprend donc un module de prétraitement et un module de calcul (*fig.V.1*) :

- le prétraitement et le contrôle des paramètres du recuit et du modèle sont effectués par l'ordinateur hôte. Le prétraitement inclut le calcul de la CCT et la préparation du champ binaire de contrainte $b(t) = [MB(t-1) \text{ xor } \hat{o}(t)]$. La charge de calcul est négligeable. Un premier bras optique projette ce champ de contrainte sur la puce.

- la place du processeur PPOS dans la chaîne correspond bien sûr au *module d'optimisation* par relaxation stochastique du champ d'étiquettes. Le fonctionnement de la puce est exactement celui pour lequel elle avait été conçue (minimisation de l'énergie dans le cas du modèle d'Ising - cf. Chap.III,§5 et §6), à ceci près qu'un *champ de contrainte binaire* est projeté sur la puce pendant toute la durée du recuit (cf. Chap.IV,§6.3).

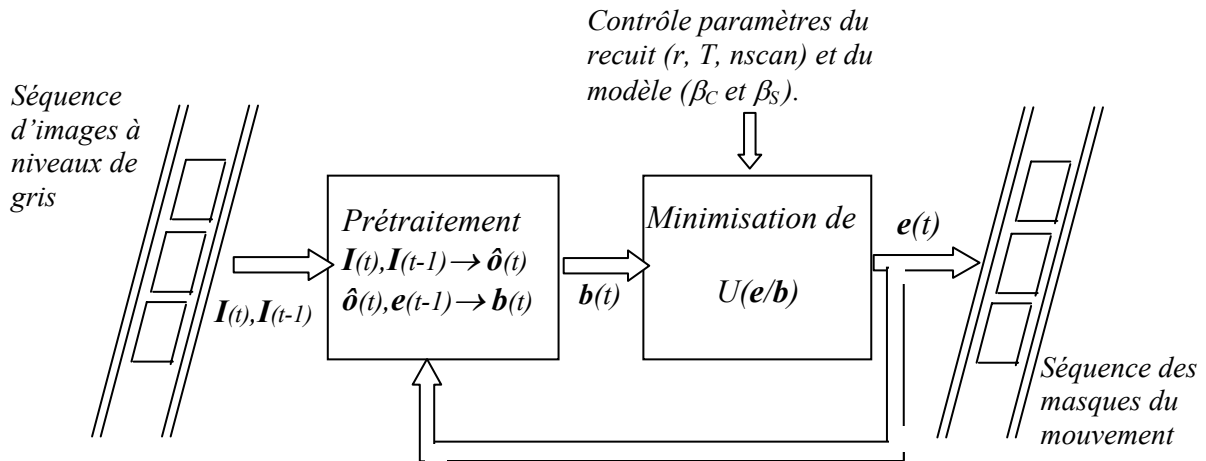


Fig.V.1 : Elements de la chaîne de traitement d'images. Le prétraitement est réalisé sur l'ordinateur hôte. Le PPOS prend en charge la régularisation du champ binaire $\mathbf{B}(t)$ pour construire le masque binaire des objets mobiles $\mathbf{MB}(t)$. L'ordinateur hôte contrôle aussi les paramètres du modèle et du recuit.

Le module d'optimisation utilisant la puce SPIE600 peut comprendre un deuxième bras optique ou non ; suivant un ordre de complexité croissante, on a étudié deux prototypes notés respectivement (E) et (O) :

(E) : Interconnexions Electriques. La simulation du modèle d'Ising sur SPIE600 (Chap.III, §6.1) est complétée par l'introduction d'un champ de contrainte binaire b . On n'utilise qu'un seul bras optique pour l'introduction de ce champ binaire à régulariser : celle-ci est effective grâce aux interconnexions *électriques* aux quatre plus proches voisins de SPIE600. La force locale de mise à jour pour la détection du mouvement (Chap.IV,§6.3) comporte des termes engendrés de façon électronique et de façon optique :

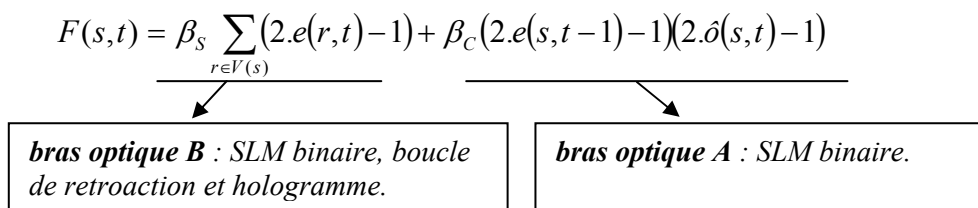
$$F(s,t) = \beta_s \sum_{r \in V(s)} (2.e(r,t) - 1) + \beta_c (2.e(s,t) - 1)(2.\hat{o}(s,t) - 1)$$

terme de **régularisation**,
calculé et disponible sur le PE
de façon électronique.

terme de **rappel** précalculé sur
l'ordinateur hôte et disponible sur
la puce par des moyens optiques.

Ce premier montage a permis de démontrer en cours de route *le débruitage d'images binaires à cadence vidéo* [Cassin98] (on remplace tout simplement le champ de contrainte binaire b par l'image à débruiter - cf. Chap.I,§5.1 et Chap.IV,§6.3). On trouvera des exemples de démonstration dans le Chap.VI,§4.1.

(O) : Interconnexions Optiques. Par rapport au premier montage de démonstration (E), le nouveau système comprend une innovation majeure, à savoir un *boucle de rétroaction optique* permettant de réintroduire optiquement le champ de labels et de reconfigurer les interconnexions entre PE (deuxième bras optique). Les interactions électriques sont coupées ; la force locale de mise à jour sur chaque PE est alors totalement engendrée par des moyens optiques :

$$F(s,t) = \beta_s \sum_{r \in V(s)} (2.e(r,t) - 1) + \beta_c (2.e(s,t) - 1)(2.o(s,t) - 1)$$


bras optique B : SLM binaire, boucle de retroaction et hologramme.

bras optique A : SLM binaire.

L'interconnexion des PE par des moyens optiques (grâce à des DOE -pour *Diffraction Optical Element*) est intéressante pour plusieurs raisons :

- Tout d'abord, il y a un intérêt d'ordre fondamental dans l'étude des performances d'un système d'interconnexion optiques, et le démonstrateur s'y prête bien : chaque cellule dispose naturellement d'entrées optiques (pour la génération de nombres aléatoires). Il s'avère que ces entrées peuvent être utilisées non seulement pour introduire de façon parallèle l'image à traiter (grâce à un premier SLM, le *SLM-A*), mais aussi pour réaliser l'interconnexion entre cellules voisines (grâce à un deuxième SLM - le *SLM-B* - et un réseau de Damman).
- Toutes les applications envisagées (restauration, B-codage, détection du mouvement) nécessitent un voisinage invariant par translation (*shift invariant*), particulièrement adapté aux interconnexions optiques ; néanmoins, la topologie du voisinage dépend de l'application envisagée. Il doit donc être possible de reconfigurer ces interconnexions sans toucher à l'électronique. Dans le cas optique, seul un élément holographique extérieur au circuit est à remplacer.
- Enfin, des noyaux de convolution (i.e. voisinages) étendus encombrant la circuiterie des processeurs élémentaires, ce qui compromet à la fois leur complexité individuelle et la densité totale de pixels de la matrice. Dans le démonstrateur (E), le voisinage s'étend à peine aux quatre plus proches voisins, ce qui limite le nombre d'applications possibles (et leurs performances éventuelles).

2. Architecture Optique

2.1 Introduction.

Ce premier démonstrateur utilise uniquement des composants macro-optiques pour réaliser les fonctions d'imagerie et convolution. Deux bras optiques (notés respectivement A et B) définissent l'architecture optique (voir *fig.V.2* et *photo.V.1*) :




Fig.V.2: Les deux bras optiques (A) et (B) du démonstrateur.

- Les deux SLMs en réflexion sont disposés pour une modulation d'amplitude.
- CSP : cube séparateur de polarisation.
- CGH : hologramme synthétique.
- L : Lentille (doublet). Les doublets L_1 et L_2 sont semblables et de distance focale f_1 . Le doublet L_3 possède une distance focale f_3 .

- (A) Un premier bras (replié) permet l'introduction par des moyens optiques de la séquence d'images à traiter, prétraitée et convenablement codée sur un premier modulateur spatial de lumière (SLM-A) fonctionnant à cadence vidéo. Le système d'imagerie est tout simplement un système afocal réalisé au moyen d'une paire de doublets.

- (B) Un deuxième bras permet de réaliser le bouclage du champ de labels ainsi que les interconnexions optiques entre les PE. Il s'agit d'un montage corrélateur de type Vander Lugt 4-f, incluant un SLM binaire ferroélectrique (SLM-B) et un réseau de Damman (le noyau de convolution responsable du système de voisinage).

2.2 Grandissement du système d'imagerie (bras A et B).

2.2.1 Description des contraintes géométriques.

Les caractéristiques géométriques des éléments imagés étant différentes (taille et pas des pixels du SLM par rapport à la taille et la disposition particulière des photodétecteurs sur la puce SPIE600), il n'existe pas un grandissement qui mette en correspondance exacte chaque pixel (ou chaque groupe de pixels, i.e. *macropixel*) sur les photodétecteurs de la puce. En particulier, les PEs de SPIE600 ne forment pas une grille carrée, mais rectangulaire (voir fig.V.3 ci-dessous).




Fig.V.3 : Paramètres géométriques du circuit SPIE600. Les mesures ont été refaites au microscope après la fonte, et correspondent à peu près au layout préparé par A. Dupret et J.C. Rodier [Dupre95b].

Par contre, la grille de pixels du SLM est carrée (voir Annexe SLM) ; les pixels du SLM mesurent 14 µm de côté, pour une zone inactive entre pixels de 1 µm (facteur de remplissage de 87%). Il faut –en principe- réaliser un grandissement légèrement différent suivant les axes X et Y . Ceci est facile à réaliser en inclinant légèrement la puce par rapport à l'axe optique, à condition que les aberrations ne deviennent pas trop importantes. Il suffit de trouver le grandissement approprié sur, disons, l'axe Y : le grandissement sur X sera alors ajusté en inclinant légèrement la puce. Le problème est rendu ainsi unidimensionnel.

Nous verrons ci-dessous qu'il faut faire intervenir trois paramètres entiers n_1 , n_2 et n_3 , en plus du grandissement optique $G=f_3/f_1$, pour examiner toutes les contraintes imposées par l'éclairage des photodétecteurs de SPIE600 à partir des pixels du SLM (A ou B) : les trois grandeurs géométriques l_p , a et b_{py} qui caractérisent SPIE600 (dans la dimension Y) sont introduites en haut de la figure V.4, alors que le bas de cette figure illustre la matrice

du SLM décrite par les paramètres l_s et b_p , supposés ici agrandis d'un facteur G . Etudions successivement les contraintes concernant les trois paramètres n_1 , n_2 et n_3 , avant de conclure sur leur compatibilité, qui définit un ensemble de plages autorisées pour G . On se souviendra que SPIE600 comporte 24x24 PEs. On cherchera à maximiser la largeur de la plage et le nombre de PEs utilisées.

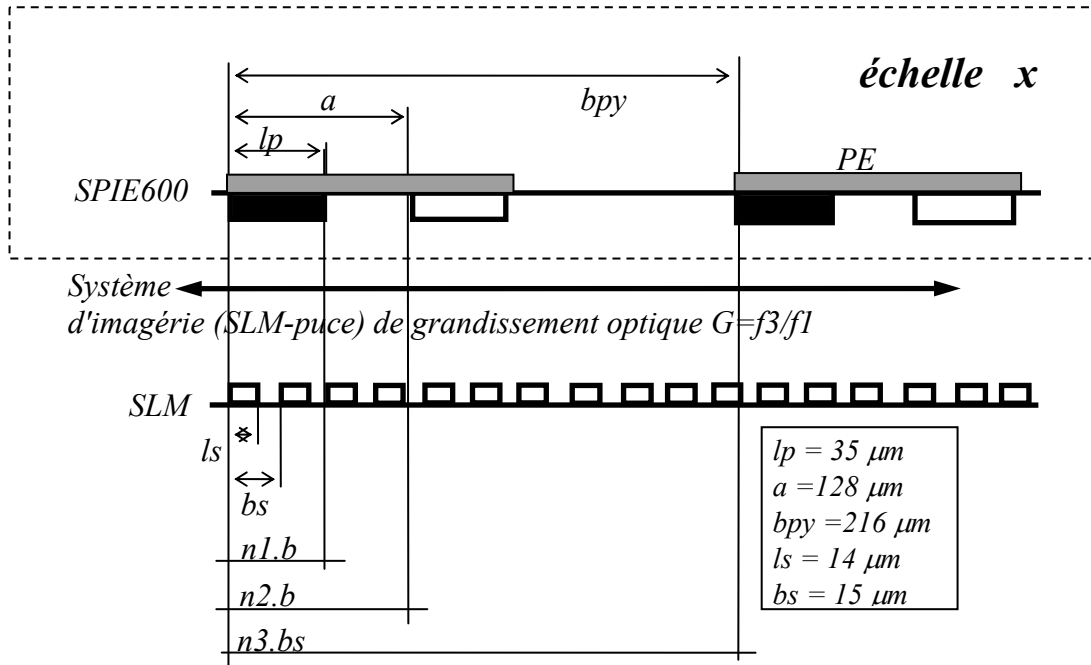


Fig.V. 4 : Conjugaison optique entre le SLM et la puce. Les entiers n_1 , n_2 , et n_3 décrivent respectivement la taille du macropixel, le nombre de pixels correspondant par conjugaison optique à la distance entre deux photodétecteurs + et - d'un même PE et enfin le nombre de pixels correspondant à la distance entre deux PEs voisins.

2.2.2 Description des paramètres et calcul du grandissement optimal.

n_1 : nombre de pixels du SLM entièrement imagés dans la taille du photodétecteur $lp = 35 \mu m$ par conjugaison optique (fig.V.5).

Un bord d'une largeur égale à B pixels permet de rendre la condition sur le grandissement moins restrictive ; il donne en même temps une certaine robustesse contre les défauts d'alignement ($\Delta < G.bs$).

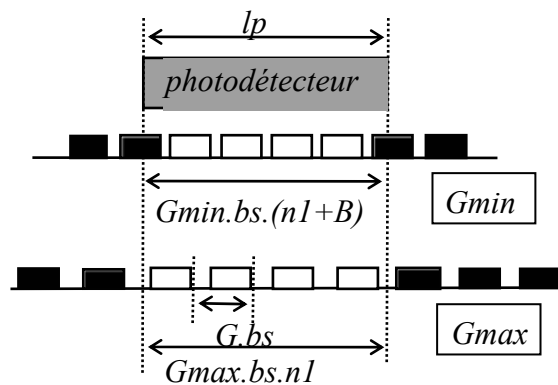


Fig. V.5 : Plage pour le grandissement G en fonction du paramètre n_1 . Dans l'exemple, $n_1=4$ et $B=1$. Un macropixel mesure alors 6 pixels de côté.

Le grandissement G peut varier sur la plage :

$$(1) G_{\min}^{n1} \leq G \leq G_{\max}^{n1}, \text{ avec } G_{\min}^{n1} = \frac{lp}{bs.(n1+B)} \text{ et } G_{\max}^{n1} = \frac{lp}{bs.n1}.$$

On appellera **macropixel** la matrice carrée de pixels actifs du SLM qui sont mis en correspondance avec un photodétecteur de la puce. Un macropixel est formé de $(n1+2.B)^2$ pixels.




Fig. V.6 : Contraintes pour le grandissement G en fonction du paramètre $n2$. Dans l'exemple, $n2=5$, $n1=2$ et $B=1$ (macropixel 3×3).

$n2$: nombre de pixel du SLM correspondant par conjugaison à la distance ($a = 128 \mu\text{m}$) entre une paire différentielle de photodétecteurs (fig.V.6). On a :

$$(2) G_{\min}^{n2} \leq G \leq G_{\max}^{n2},$$

avec :

$$G_{\min}^{n2} = \frac{a+lp}{bs.(n2+n1+B)} \text{ et}$$

$$G_{\max}^{n2} = \frac{a}{bs.n2}.$$

La condition (2) garantit une bonne couverture lumineuse des photodétecteurs pour un erreur d'alignement allant jusqu'à $\Delta = G_{\min}.bs.B$ dans le cas le plus contraignant (grandissement $G = G_{\min}$, voir fig.V.7).




Fig.V.7 : $n1=1$ (au moins un pixel du SLM par détecteur) et $B=1$. L'image du macropixel est plus grande que le photodétecteur ($35 \times 35 \mu\text{m}^2$).

n_3 : nombre de pixel du SLM correspondant au pas bp (fig.V.8) entre deux PE adjacents ($bp = 216 \mu m$).

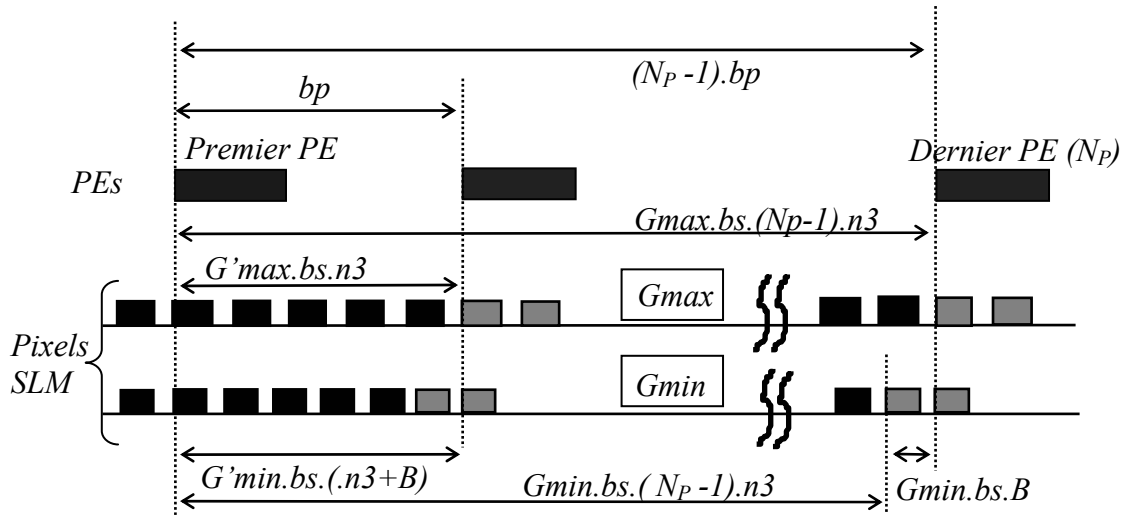


Fig. V.8 : Contraintes sur le grandissement en fonction du paramètre n_3 . Dans l'exemple $n_3=5$ et $B=1$. N_p est le nombre de PE fonctionnels sur une ligne de la matrice.

On a pour deux PEs adjacents :

$$(3') \quad G'_{\min} = \frac{bp}{bs.(n_3 + B)} \leq G \leq \frac{lp}{bs.n_3} = G'_{\max}$$

Mais si l'on considère l'alignement entre un nombre N_p (< 25) de PE fonctionnels, on obtient la condition beaucoup plus restrictive :

$$(3) \quad G_{\min}^{n_3} \leq G \leq G_{\max}^{n_3}, \text{ avec } G_{\min}^{n_3} = \frac{bp}{bs.\left(n_3 + \frac{B}{(N_p-1)}\right)} \text{ et } G_{\max}^{n_3} = \frac{bp}{bs.n_3}.$$

La condition (3) assure que le défaut d'alignement pour tout PE d'un ensemble de N_p processeurs élémentaires adjacents reste inférieur à $G.bs.B$.

On a procédé en traçant sur le même graphique les différentes plages permises pour le grandissement G en fonction de n_1 , n_2 et n_3 , et cela pour divers valeurs de N_p et B - allant de seulement deux PE fonctionnels ($N_p=2$) jusqu'à la totalité des PE ($N_p=24$). Un exemple de tracé est donné dans fig.V.9 pour $N_p=6$ et $B=1$. Dans l'exemple, on voit que l'intersection des trois plages n'est pas nulle pour le choix des paramètres $n_1=1$, $n_2=6$ et $n_3=10$. Mais la plage commune est assez étroite.




Fig.V.9. Exemple : intervalle de tolérance pour G , avec $N_{PE} = 4$ et $B=1$. On cherche l'intersection non nulle des intervalles pour n_1 , n_2 et n_3 , mais telle que n_2 et n_3 soient les plus grands ; on utilise alors au mieux la résolution spatiale du SLM pour éviter la diaphonie.

En étudiant des figures de ce type on a pu construire le *tab.V.1* donnant les meilleures plages de tolérance pour le grandissement G et les valeurs correspondantes pour N_p , n_2 et n_3 , n_1 et B . Seulement 4 ou 9 PEs peuvent être alignés à la fois, à moins (comme on l'a fait) de rattraper le défaut d'alignement tous les $n_3 \times N_p = 10 \times 4 = 40$ pixels (décalage d'un pixel tous les 40 pixels du SLM, pour rattraper un décalage de $\Delta = G \cdot bs \cdot B$ sur l'image).

On a procédé de la même façon sur l'axe X, axe pour lequel les conditions d'alignement sont moins sévères (il n'y a qu'une seule géométrie pour la grille de photodétecteurs - voir *fig.V.3* ; en particulier la condition (2) n'est pas à satisfaire).

	$a = 128 \mu m$
$b_{px} = 214 \mu m$	$N_p = 4$, $n_1=1$, $n_2=6$, $n_3=10$ et $B=1$ $1,38 < G < 1,43$
$b_{py} = 216 \mu m$	$N_p = 4$, $n_1=1$, $n_2=6$, $n_3=10$ et $B=1$ $1.39 < G < 1.42$ $N_p = 9$, $n_1=2$, $n_2 = 10$ et $n_3=17$ $0.8534 < G < 0.8538$

Tab.V.1 : Tolérances sur le grandissement et paramètres de correspondance.

On constate alors qu'il n'est pas nécessaire d'incliner la puce pour obtenir un grandissement différent sur chaque axe, car l'intersection des intervalles de tolérance pour $bp=bp_y=216\mu\text{m}$ et $bp=bp_x=214\mu\text{m}$ n'est pas nulle (à condition de choisir $N_p=4$). L'intervalle de tolérance finale pour le grandissement est :

$$G_{min}=1,39 \leq G \leq G_{max}=1,42$$

2.2.3 Choix des optiques.

Le grandissement moyen est de $G=1,40 \pm 0,02$. L'erreur relative tolérée autour de la valeur moyenne est de $\pm 1,4\%$. On pourra facilement couvrir la plage en déplaçant légèrement les lentilles du système télescopique.

Les doublets commerciaux présentent une dispersion des caractéristiques (longueur focale) de moins de 2%. On a choisi d'utiliser pour ce premier démonstrateur macro-optique une paire de doublets commerciaux (Melles-Griot).

La fig.V.10 nous a aidé dans la recherche de la meilleure paire de doublets : les lignes horizontales représentent les distances focales des doublets disponibles dans le catalogue (en mm) pour la longueur d'onde nominale du SLM (680nm). Les marques correspondent aux valeurs des focales multipliées respectivement par G_{min} et G_{max} . Une paire utile est trouvée quand la focale d'un doublet (une ligne horizontale) tombe entre les marques correspondant à un autre doublet.

On choisit ainsi la paire de doublets suivante (Catalogue Melles-Griot 97-98, p. 55) :

L_1, L_2 : Ref .M.G. 01 LAO 068 : focale $f_1=56,07$ mm (680nm) et diamètre $\Phi_1 = 19$ mm.

L_3 : Ref. M.G. 01 LAO 114 , focale $f_3= 78,3$ mm (680nm) et diamètre $\Phi_3 = 31,5$ mm.

On a : $G = f_3/f_1 = 1,4$ à 680 nm.

Avec ce choix de paramètres et de composants, il est possible d'utiliser la totalité des PEs de la puce SPIE600 ($N_{PE}=24 \times 24 = 576$ PEs). La fig.V.11 montre l'image d'une lettre




Fig.V.10 : Choix des doublets. Gardant à l'esprit les contraintes d'encombrement (voir Photo.V.2), on a préféré des distances focales relativement grandes pour pouvoir placer aisément d'autres éléments dans le système optique

"C" telle qu'elle sera codée (en "double-voie") sur le SLM binaire, suivant la géométrie dictée par le jeu de paramètres final $n_1=1$, $n_2=6$, $n_3=10$ et $B=1$.




Fig.V.11 : Image binaire représentant la lettre "C" codée en mode double-voie 24x24 sur le SLM 256x256. On a $n_1=1$, $n_2=6$, $n_3=10$ et $B=1$.

2.3 Eclairage moyen sur les photodétecteurs.

Un macropixel est formé par 9 pixels du SLM disposés dans un carré de trois pixels




Fig.V.12 : Dans l'exemple, $n_1=1$ et $B=1$ (macropixels 3x3). Le carré grisé représente le photodétecteur, les carrés vides représentent l'image des pixels du SLM. L'éclairage intégré arrivant sur les photodétecteurs varie par translation : (a) éclairage maximal (b) éclairage minimum.

de côté $(n1+2.B)$. Il comporte donc une zone inactive qui peut affecter l'uniformité d'éclairage par translation (fig.V.12).

Pour chaque valeur du grandissement G , l'éclairage sur chaque photodétecteur peut varier entre deux bornes. Soit E l'éclairage uniforme sur la surface de la puce s'il n'y avait pas d'aire inactive entre pixels. L'éclairage relatif sur un photodétecteur quelconque sera défini par :

$$ER_{PE} = \frac{E_{PE}}{E} = \frac{S_{\text{éclairé}}}{S_{\text{totale}}}$$

La surface totale du photodétecteur est toujours égale à $lp^2=35 \times 35 \mu\text{m}^2$, mais la surface éclairée varie entre deux bornes (situations (a) et (b) de la fig.V.12). L'éclairage relatif varie donc entre deux bornes ER_{min} et ER_{max} .

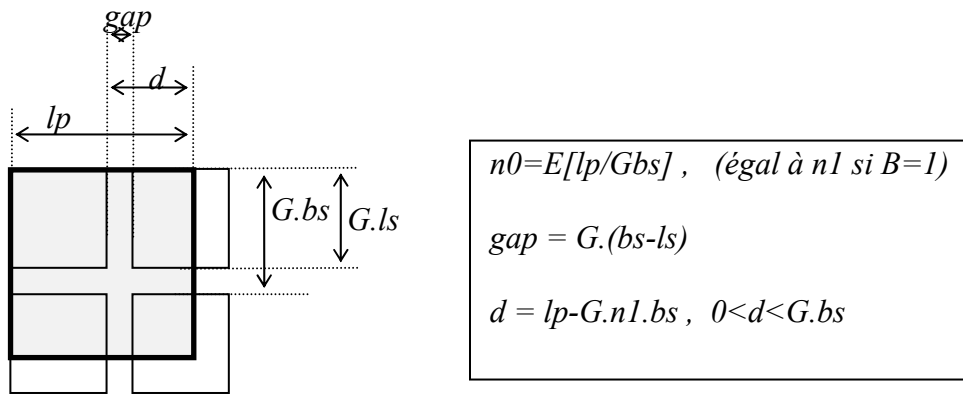


Fig.V.13 : description des quantités utiles à l'évaluation de la dispersion d'éclairage.

On se propose d'évaluer la dispersion de l'éclairage pour la valeur du grandissement choisi $G=1,4 \pm 0,02$. Plusieurs situations sont possibles ; la fig.V.13 permet d'interpréter les inéquations suivantes :

- Si $d < gap$:

$$E_{\min} = \frac{E}{lp^2} (G.n0.ls)^2 \quad \text{et} \quad E_{\max} = \frac{E}{lp^2} (G.n0.ls + d)^2$$

- Si $gap < d < G.ls$:

$$E_{\min} = \frac{E}{lp^2} (G.n0.ls + d - gap)^2 \quad \text{et} \quad E_{\max} = \frac{E}{lp^2} (G.n0.ls + d)^2$$

- Si $G.ls < d < G.bs$:

$$E_{\min} = \frac{E}{lp^2} (G.n0.ls + d - gap)^2 \quad \text{et} \quad E_{\max} = \frac{E}{lp^2} (G.(n0 + 1).ls)^2$$




Fig.V.14 : Eclairage Relatif (ER) sur chaque photodétecteur en fonction du grandissement G . Pour le grandissement retenu ($G=1,4$), l'éclairage relatif est égal à 88% avec une dispersion due à la translation de 5%.

La fig.V.14 montre comment évoluent les bornes pour l'éclairage (ER_{min} et ER_{max}) en fonction du grandissement optique. L'éclairage varie sur les photodétecteurs car il n'y a pas de coïncidence parfaite entre l'image des macropixels et la géométrie de la puce. Pour $G=1,4$ l'éclairage moyen relatif vaut $ER=88\%$, avec un écart de $\pm 5\%$ (dans le pire des cas).

Si cette variation s'avérait trop importante pour le bon fonctionnement du démonstrateur, on pourra toujours initialiser le système par une séquence "d'apprentissage automatique" qui rendra certains macropixels moins lumineux pour compenser les défauts d'éclairage des autres (on a en fait 10 niveaux de gris par macropixel, car le macropixel contient 9 pixels réels⁵⁵). Cette même stratégie peut être utilisée pour compenser les variations d'éclairage provenant d'autres défauts d'éclairage du système (aberrations de champ par exemple).

⁵⁵ Remarquons aussi qu'il suffirait de quatre niveaux de gris distincts pour pouvoir implanter l'algorithme de détection du mouvement avec terme de rémanence (Chap.IV, §6.2.2). En effet, dans ce cas les deux derniers termes (bi-valués) de la force optique:

$$F_p + F_c = \beta_p(2.e(r,t-1)-1) + \beta_c(2.e(s,t-1)-1)(2.\delta(s,t)-1)$$

2.4 Système télécentrique et afocal.

2.4.1 Géométrie

La figure fig.V.15 est un schéma du système d'imagerie (bras optique A ou B). Il s'agit d'un système télécentrique, ce qui permet de diminuer les aberrations et éventuellement d'améliorer le couplage optique entre transducteurs optoélectroniques. Ceci n'est pas essentiel dans ce premier démonstrateur pour lequel les transducteurs sont la cellule CLF d'une part, et le photodétecteur silicium d'autre part. Dans une nouvelle version de la puce où il sera fait usage de modulateurs à puits quantiques (Chap.VII,§4), il est néanmoins important de travailler avec des faisceaux optiques en incidence normale sur la cavité résonnante du modulateur.




Fig.V.15 : Estimation de l'ouverture numérique du système et calcul du diamètre des doublets pour les bras optique A et B.

Description des paramètres géométriques du montage (fig.V.15) :

- $f_1 = 56.1$ mm et $f_3 = 78.3$ mm pour $\lambda = 680$ nm ; $G = f_3 / f_1$ (grandissement optique) = 1,4.
- $e = f_1 \cdot \delta$, où $\delta = \lambda / l_s$. En première approximation, l'illumination sur chaque pixel est modélisée par une onde plane étendue sur une zone plus large que la taille du pixel $l_s^2 = 15 \times 15 \mu\text{m}^2$. Le faisceau réfléchi diverge à cause de la diffraction. On a : $\delta = 0,048$ rad = $2^\circ 44'$ et $e = 2,70$ mm.
- Ouverture minimum des doublets pour éviter le vignettage : Le diamètre minimum des doublets pour éviter le vignettage est égal à $D_1 = 2 \cdot R_1 = 2 \cdot (h + e)$, où $h = 2,71$ mm

engendrent quatre quantités, $\beta_p + \beta_c$, $\beta_p - \beta_c$, $-\beta_p + \beta_c$ et $-\beta_p - \beta_c$ pouvant être codées sur le SLM-A. Cependant ceci impose de restreindre la dynamique des paramètres β_p et β_c . On n'a pas poursuivi l'étude dans cette voie.

est la moitié de la diagonale du SLM (partie active du SLM la plus éloignée de l'axe optique). On a alors : $D_1 = 10,8$ mm. De même, $D_3 = 2.R_3 = 2.(G.h + e) = 13,2$ mm. Les doublets choisis ont des diamètres respectifs de 19 et 31,5 mm (§2.2.3).

- Cubes séparateurs de polarisation : Pour que le système soit afocal, il faut que $d = f_1 + f_3$ (en absence de cube séparateur). Si l'on intercale dans le chemin optique deux cubes séparateurs identiques d'indice n et d'arête A , le système reste afocal à condition de réduire la séparation entre les lentilles de la quantité $2.A.(1-1/n)$. On a alors : $d = f_1 + f_3 - 2.A.(1-1/n)$. Le côté du cube doit être supérieur à $D_2 = 13,2$ mm pour éviter le vignettage quelle que soit la position de celui-ci. On a choisi d'utiliser trois cubes de 20 mm de côté (Melles-Griot 03PBB013), d'indice de réfraction $n \approx 1,51$ à 680 nm (BK7). Dans ces conditions, $d = 134,3$ mm. L'angle α que fait le faisceau parallèle avec l'axe du système est très exagéré dans la figure : en réalité, α est de l'ordre de 2° ($\text{tg}(\alpha) = h/f_1$), et le faisceau est -dans le pire des cas - presque normal à la face du cube, ce qui limite les aberrations (de toutes façons, la traversée du cube par un faisceau parallèle permet d'éviter qu'il s'introduise de l'aberration sphérique et de l'astigmatisme).

2.4.2 Aberrations. Simulations sur CODE V.

La fig.V.16 présente les résultats du calcul des aberrations sur CODE V™. La largeur quadratique moyenne (RMS) de la tache atteint $26 \mu\text{m}$ dans le pire des cas (coins du SLM) à cause des aberrations sphériques. Néanmoins il n'est pas nécessaire de rajouter une lentille plano-concave pour réduire les aberrations de champ et éviter ainsi l'intermodulation (*cross-talk*) des signaux : une distance d'au moins $63 \mu\text{m}$ ($= 3x_b \times x_G$) sépare les images de deux macropixels adjacents (voir fig.V.17 ci-dessous)




Fig.V.17 : Aire inactive entre deux macropixels voisins (correspondant aux photodétecteurs + et - d'un même PE) : une distance de trois pixels entre les macropixels actifs suffit à éviter l'intermodulation des signaux.




Fig.V.16 : Simulation des aberrations de champ sur Code V.

Il se peut cependant que les photodétecteurs des coins de la puce soient moins illuminés que ceux du centre : un gradient de force optique des bords vers le centre est ainsi créé qui peut perturber le bon fonctionnement du recuit. Si tel est le cas, on pourra soit corriger le problème par une optique plus sophistiquée, soit utiliser une séquence d'apprentissage comme expliqué précédemment.

3. Autres éléments optiques

3.1 Modulateur Spatial de Lumière.

Le modulateur spatial de lumière est placé sur une platine de translation XYZ de faible course (pour réaliser l'alignement des pixels et ajuster le grandissement G) et un platine de rotation (pour l'alignement en rotation). Pour les détails du montage en modulation d'amplitude et l'étude des caractéristiques de transmission, voir Annexe A ; on retiendra ici un résultat utile par la suite, i.e. le contraste par imagerie : $C = (19 \pm 7) : 1$.

3.2 Eléments diffractifs (DOE) pour la convolution optique.

Le voisinage spatial est réalisé par *convolution optique*, lors de la rétroaction du champ d'étiquettes (voir fig.VI.4 au Chap.VI et fig.B.12 dans l'Ann.B). Nous avons réalisé plusieurs réseaux de Dammann binaires de phase, pour implanter un voisinage d'ordre 1, 2 et 3 respectivement. La conception et les résultats expérimentaux se trouvent

dans l'Ann.B. Nous allons rappeler ici les valeurs des efficacités de diffraction expérimentales sur les ordres utiles (tab.B.1) :

$$\left\{ \begin{array}{l} \eta_{\text{CHG-4}} = 16,5 \pm 0,6 \% \text{ pour le voisinage 4.} \\ \eta_{\text{CHG-8}} = 9,1 \pm 0,9 \% \text{ pour le voisinage 8.} \\ \eta_{\text{CHG-12}} = 7,5 \pm 0,8 \% \text{ pour le voisinage 12.} \end{array} \right.$$

4. Sources Optiques

4.1 Destruction de la cohérence spatiale de la source optique.

Si l'on utilise une source cohérente, quand plus d'une image de macropixel diffractée par le réseau de Dammann éclaire le même photodétecteur, on doit s'attendre à des phénomènes d'interférences. On doit éviter ce phénomène si l'on cherche à cumuler les contributions en *intensité*. Dans l'espoir que la taille du photodétecteur soit significativement plus large que l'interfrange correspondant à deux macropixels voisins, nous avons effectué des simulations qui finalement anéantirent cet espoir : en fait, un phénomène de *Moiré* a lieu, de sorte que le motif d'interférence dépend de la position relative du réseau par rapport à l'axe optique (ce qui est normal, étant donné que le pas du réseau est calculé pour être égal au pas du champ d'interférences produit par les deux ondes planes issues de chaque macropixel –cf. Ann.B. La fig.V.18 montre le résultat de la superposition de deux motifs de diffraction (voisinage d'ordre 1 aux quatre plus proches voisins) correspondant à deux macropixels différents éclairant le même photodétecteur central. L'interférence évolue de constructive à totalement destructive sur

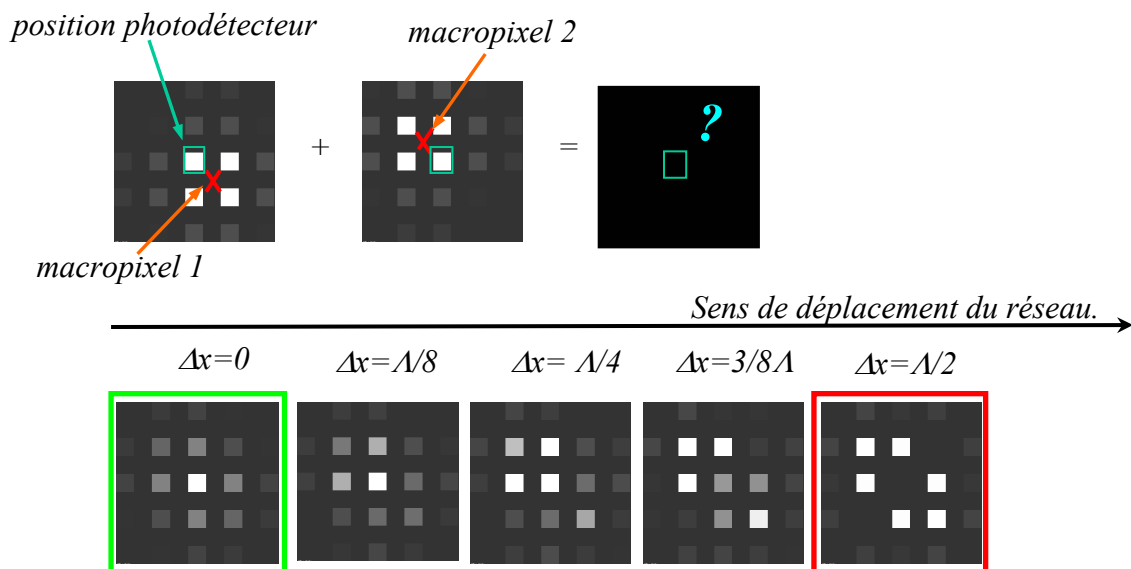


Fig.V.18 : Phénomène de Moiré. Les interférences sur le photodétecteur central peuvent être constructives (image de gauche) ou totalement destructives (image de droite), pour un déplacement du réseau de la moitié du pas (4-voisinage : $\Lambda \approx 174 \mu\text{m}$).

le photodétecteur quand on opère une translation du réseau de $\Delta x = \Lambda/2$ (Λ est le pas du réseau). Il faudrait donc contrôler la position du réseau à mieux de $\Lambda/4 \approx 174/4 = 43 \mu\text{m}$ près pour éviter que l'intensité maximale chute de moitié -l'intensité évolue comme $\cos^2(\pi/\Lambda \cdot \Delta x)$). Ceci n'est pas difficile, mais peut s'avérer irréaliste étant donné que la position optimale du réseau (celle qui engendre une interférence *constructive*) peut être différente pour des paires distantes de macropixels à cause des imperfections du système (aberrations de champ par exemple).

Il faut donc détruire la cohérence spatiale de la source. On peut toujours utiliser une lampe à incandescence, avec l'inconvénient d'un montage optique (collimation et filtrage) plus encombrant et d'une dissipation de chaleur et d'une consommation électrique bien plus importante. On peut aussi utiliser un diffuseur tournant placé devant la source laser comme dans le montage générateur de nombres aléatoires, ou bien utiliser une diode laser de qualité médiocre modulée plus ou moins rapidement pour produire de sauts de modes en séries rapides. Une fibre optique multimodale peut être utilisée pour mélanger ces modes et améliorer l'uniformité spatiale du faisceau.

Enfin, une dernière solution beaucoup plus simple et compacte et que nous avons retenue après calcul, consiste à illuminer le SLM avec un speckle *statique*, pourvu que la taille du grain de speckle imagé sur le photodétecteur soit bien inférieure à celui-ci. Puisque la superposition de deux champs de speckle semblables produit un champ de speckle de caractéristiques équivalentes aux précédents mais d'intensité double, le problème de l'interférence est ainsi réglé. On a choisi d'utiliser une fibre optique multimodale couplée directement avec une diode laser pour produire un figure de speckle statique à la sortie de la fibre (*fig.V.19*). La taille du grain de speckle est donné par [Daino80] :

$$g = \frac{\lambda}{\pi \cdot ON}, \text{ où } ON \text{ est l'ouverture numérique de la fibre.}$$

La taille du grain de speckle sur le modulateur (si l'on choisit un grandissement adéquat tel que toute la matrice carrée du SLM soit éclairée par la figure circulaire du speckle) est alors égale à :

$$g' = G' \cdot g = \frac{d}{c} \cdot \frac{\lambda}{\pi \cdot ON},$$

où d est la diagonale du SLM et c le diamètre de cœur de la fibre ($G' = 5,42$). Enfin, puisque l'on connaît le grandissement entre le SLM et la puce ($G = 1,4$), on peut exprimer la condition recherchée, à savoir que le diamètre du grain de speckle sur la puce $g'' = G \cdot g' = G \cdot G' \cdot g$ doit rester très inférieur à la taille du photodétecteur ($l_p = 35 \mu\text{m}$) :

$$g'' \ll l_p \Leftrightarrow G \cdot \frac{d}{c} \cdot \frac{\lambda}{\pi \cdot ON} \ll l_p,$$

condition qui se traduit finalement par une contrainte sur les paramètres de la fibre :

$$c \cdot ON \gg \frac{G \cdot d \cdot \lambda}{\pi \cdot l_p}; \text{ numériquement } c \cdot ON \gg 46,93 \mu\text{m}.$$

Les fibres en silice ont un diamètre de cœur de l'ordre de $70 \mu\text{m}$ pour une ouverture numérique $ON=0,21$. Dans ces conditions $c.ON \approx 15 \mu\text{m}$, et la condition n'est pas vérifiée. Par contre, les fibres plastiques ont un diamètre de cœur c de l'ordre du millimètre et une ouverture numérique $ON=0,5$. La condition est bien vérifiée : $c.ON=500 \mu\text{m} \gg 47 \mu\text{m}$. Le rapport de 500 à 47 (à peu près dix) exprime qu'il y a $10^2=100$ grains de speckle par photodétecteur.




Fig.V.19 : Source de lumière (speckle statique) pour le SLM du bras (A) ou (B). La condition sur la taille du grain de speckle implique un choix de fibre tel que $c.ON > 47 \mu\text{m}$.

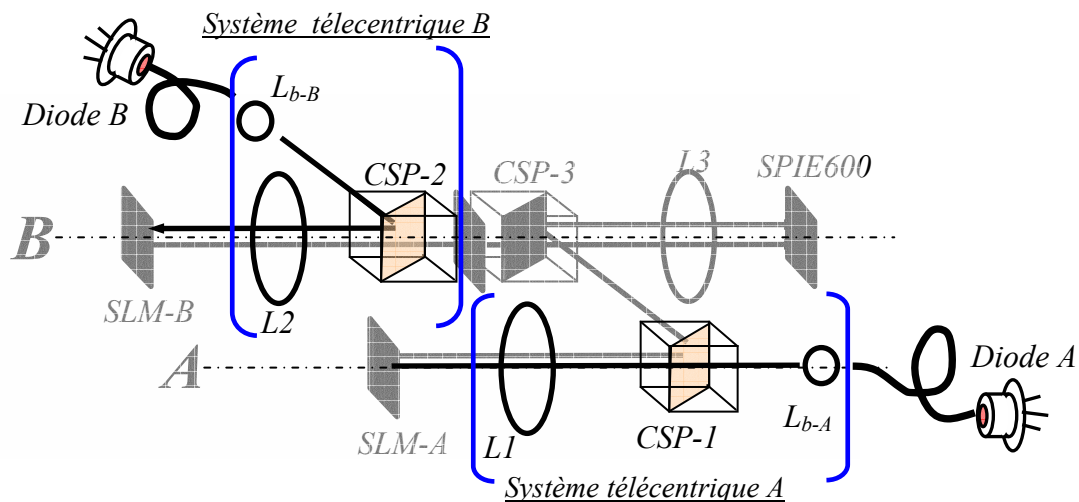


Fig.V.20: Sources optiques pour les SLMs en réflexion. L'image de la face de sortie de la fibre optique sur le SLM est réalisée grâce à une lentille bille (L_b) et l'un des doublets du montage d'imagerie SLM/PUCE (L_1 ou L_2). Le système est télécentrique (les systèmes A et B sont semblables).

4.2 Système télécentrique Diode Laser / SLM

Pour le système d'imagerie entre la sortie de la fibre et le SLM, on a choisi d'utiliser un système télécentrique (fig.V.20 et 21). Le faisceau éclairant le SLM est normal à celui-ci. Il pourra repartir -après réflexion- parallèle à l'axe optique vers le système télécentrique SLM/PUCE (§2.4).

Le schéma de la fig.V.21 rend compte des paramètres du système, composé d'une lentille bille et d'un doublet (le doublet L_1 ou L_2 du système télécentrique SLM/PUCE). La lentille L_b choisie est une lentille bille de diamètre 10mm et de focale $f_b=7,34$ mm (Edmund Sci. D32748). Le grandissement $f_1/f_b=7,6$ est donc légèrement supérieur à la valeur calculée précédemment ($G'=5,2$). La condition pour la taille des grains est modifiée mais reste toujours vérifiée pour une fibre optique plastique de 1mm de cœur et d'ouverture numérique $ON=0,5$. Le système fibre/SLM (fig.V.21) est télécentrique. Pour éviter le vignettage à la sortie de la fibre, l'ouverture numérique de la lentille L_b doit être supérieure à $ON=0,5$. On a alors $\Phi_b > c+e = c+2.tg(\delta).f_b = 9,4$ mm pour le diamètre utile de la lentille (ce qui est presque vérifié, le diamètre utile de la lentille bille choisie étant de 9mm).




Fig.V.21 : Système télécentrique pour l'éclairage du SLM.

5. Bilan optique et choix des sources laser.

On se propose d'établir ici un cahier de charges pour la puissance des sources optiques. Celui-ci est bien sûr fonction des pertes optiques du système, mais dépend également de la cadence de fonctionnement de chaque partie du système. Des sources distinctes sont utilisées pour alimenter chaque bras optique ; on obtient de la sorte un contrôle plus aisé de la contribution relative à chaque terme de la force optique (terme de

contrainte β_C et terme de régularisation β_S -cf §1.1). Pertes optiques et cadence de fonctionnement sont différentes pour le bras optique (A) et pour le bras optique (B).

5.1 Définition des quantités utiles.

- $P_{A/B}$: puissance optique de la source laser A (respectivement B).
- $p_{A/B}^{ON/OFF}$: puissance optique provenant de la source A (resp. B) et arrivant sur un photodétecteur individuel, selon que le macropixel correspondant du SLM se trouve à l'état ON ou OFF. On a alors : $\Delta p_{A/B} = p_{A/B}^{ON} - p_{A/B}^{OFF}$, puissance optique utile qui sera convertie en courant par la détection différentielle.
- $F_{A/B}$: cadence de fonctionnement du modulateur A (respectivement B). On a $F_A \ll F_B$, car "l'image" à traiter -i.e. le champ de contrainte $b(s,t) = (2\delta(s,t) - 1) \cdot (2e(s,t-1) - 1)$ - est fixe pendant toute la durée du recuit. La cadence du recuit est F_A . On dira que le bras B impose les contraintes critiques : il faut d'une part que l'intervalle de temps $t_B = 1/F_B$ soit suffisant pour réaliser la rétroaction électronique, soit $t_B > t_{boucle}$ (acquisition du champ courant $e(t)$ sur la puce, conversion au format image double-voie, et envoi sur le CLF/CI en utilisant l'électronique - cf. Chap.VI,§3.2 et Ann.D,§ 2.5.2) et d'autre part que $F_B < F_{CLF} = 2kHz^{56}$ cadence maximale de mise à jour du SLM. Si l'on cherche à respecter la qualité du recuit (i.e. le *recuit sérieux*, c.à.d. environ 1000 itérations) et si N_C est le nombre de couleurs, on a $N_{iter} = 1000 \times N_C$ itérations -c'est le nombre de fois que la boucle de rétroaction fonctionne pour chaque image et la cadence du recuit est alors $F_A = F_B / N_{iter}$.
- ΔE_{min} : On a vu au Chap.III,§5.3.3 que l'éclairement requis pour faire commuter l'état d'un PE à 250 kHz est d'environ 10mW/cm² (puissance du speckle optique). Ceci correspond à une énergie de commutation par PE d'environ $\Delta E_{min} = 0,5$ pJ (taille de la fenêtre optique : 35x35µm²). Cette quantité détermine le temps minimal d'intégration pour le photodétecteur (et donc une borne supérieure pour la cadence de recuit) étant donnée la puissance optique de la source. Si celle-ci s'avérait insuffisante, on pourrait toujours réduire la cadence du système, mais aussi travailler avec un nombre plus réduit de PEs ($N_{PE} < 24 \times 24$) de façon à répartir la puissance optique disponible sur une aire plus petite.

On notera η_{xx} la fraction de lumière incidente transmise par un élément optique individuel ou par un ensemble d'éléments du système. On a en particulier :

$$\eta_{Ci} = 95\% \text{ pour les trois cubes polarisants } CSP_1, CSP_2 \text{ et } CSP_3 \text{ -à } 680 \text{ nm.}$$

⁵⁶ On peut utiliser le CLF/CI à sa cadence maximale de 2kHz sans *inverser chaque image* pendant un temps qui doit rester inférieur à quelques secondes ; ensuite il faut dérouler les images inverses sur le SLM (voir remarque « problème de compensation des charges » dans l'Ann.A,§2.1).

$\eta_{L1/L2} = 92\%$, pour les doublets (pertes de 4% par réflexion -les doublets ne sont pas traités antireflet).

$\eta_{SLM}^{ON} = 25\%$, transmission du SLM à l'état ON et $\eta_{SLM}^{OFF} = \eta_{SLM}^{ON} / C \approx 25/19 = 1,32\%$ pour l'état OFF ($C \approx 19:1$, contraste du SLM, voir Ann.A).

5.2 Equation du bilan optique.

L'inéquation qui résume le cahier de charges en puissance pour la source optique A ou B est tout simplement donnée par la formule :

$$F_B \cdot \Delta E_{\min} \leq \Delta p_{A/B}$$

Autrement dit, il faut que la rétine ait le temps d'intégrer l'image présentée sur le SLM-A ou B à la cadence F_B (la fréquence F_B est la cadence de "lecture" par la puce des informations présentées sur les deux modulateurs, même si l'image dans le modulateur A ne change qu'à la cadence F_A). La puissance intégrée sur un photodétecteur (correspondant à un "1" codé en mode *double-voie*) est donnée par :

$$\Delta p_{A/B} = p_{A/B}^{ON} - p_{A/B}^{OFF} = p_{A/B}^{ON} \left(1 - \frac{1}{C}\right),$$

où $p_{A/B}^{ON} = \eta_{A/B}^{ON} \cdot P_{A/B}$ est la puissance optique arrivant sur un photodétecteur quand le macropixel correspondant est à l'état ON. Dans cette dernière expression, $\eta_{A/B}$ est le facteur d'atténuation globale de l'intensité dans le parcours entre la source optique A (ou B) et *un seul photodétecteur* de la puce ; $\eta_{A/B}$ rend compte non seulement des pertes optiques du système, mais aussi de la réduction d'énergie du fait de sa répartition -plus ou moins équitable- sur tous les photodétecteurs fonctionnels. Finalement l'inéquation fixant la puissance optique de la source optique A (et B) s'écrit :

$$P_{A/B} \geq \frac{\Delta E_{\min}}{\eta_{A/B}^{ON}} \cdot F_B \quad (1)$$

5.2.1 Inéquation pour le bras A.

Le détail des pertes optiques pour le bras (A) conduit à l'expression suivante pour le facteur d'atténuation global (le parcours de la lumière depuis la source A jusqu'à la surface de la puce se retrouve dans l'ordre des facteurs -voir fig.V.22):

$$\eta_A^{ON} = \eta_{D-f} \cdot \eta_f \cdot \eta_{Lb} \cdot \frac{\eta_{C1}}{2} \cdot \eta_{L1} \cdot \eta_{vign} \cdot \eta_{rep} \cdot \eta_{inact} \cdot \eta_{SLM}^{ON} \cdot \eta_{L1} \cdot \eta_{C1} \cdot \eta_{C3} \cdot \eta_{L3} \quad (a)$$




Fig. V.22: Décompte des pertes optiques pour le bras (A). Les pertes pour le bras (B) incluent en plus l'efficacité de l'hologramme synthétique (CGH) sur l'ordre utile η_{CGH} .

La formule (a) ci-dessus appelle quelques explications :

- Les cinq premiers termes correspondent aux pertes dans le système d'imagerie télécentrique Diode/SLM. Le facteur deux rend compte de l'énergie perdue dans le premier cube, le faisceau sortant de la fibre optique n'étant pas polarisé. Le produit des trois premiers termes a été évalué expérimentalement grâce une diode laser de test de 25 mW de puissance et de caractéristiques d'émission semblables aux diodes finales (divergence $35^\circ - 8^\circ$). Le couplage direct avec une fibre plastique ($ON=0,5$ et $c=1\text{mm}$) implique alors une distance maximale entre la sortie de la diode et la fibre de moins de $x=c/2\text{tg}(30^\circ)=0,87\text{mm}$, mais une partie de l'énergie lumineuse est perdue irrémédiablement. Dans ces conditions, on a pu mesurer une transmission de l'ordre de $\eta_{D-f} \cdot \eta_f \cdot \eta_{Lb} = 2,6/25 = 10,4\%$.
- Les quatre termes suivants correspondent aux pertes sur le SLM. On a dans l'ordre :
 - Vignettage du faisceau arrivant sur le SLM. Le grandissement du système télécentrique Diode/SLM ($G'=f_l/f_b=7,6$) conduit à un faisceau circulaire arrivant sur le SLM de diamètre 7,6 mm. La surface utile du SLM vaut $3,84 \times 3,84 \text{mm}^2$. Le rapport des surfaces faisceau/SLM conduit à $\eta_{vign} = 32,5\%$.
 - Répartition de l'énergie sur tous les macropixels et pertes dues aux pixels inutilisés. On suppose que le faisceau illumine uniformément toute la surface du

SLM. La surface du SLM correspondant à un photodétecteur (par conjugaison optique) mesure exactement $l_p/G = 25 \mu\text{m}$ de côté⁵⁷. S'il n'y avait pas de zones inactives entre pixels, alors le facteur d'atténuation dû à la répartition de l'énergie serait égal à $\eta_{rep} = (25 \times 25) \mu\text{m}^2 / (3,84 \times 3,84) \text{mm}^2 = 4,2 \cdot 10^{-5}$.

C'est le facteur d'atténuation le plus important, mais il tient compte de la répartition de l'énergie émise par une seule source entre 24x24 PEs.

- Si l'on tient compte des zones inactives (et si on les suppose absorbantes), alors il faut inclure une atténuation supplémentaire, variable, dont la valeur moyenne calculée précédemment (§2.3) vaut $\eta_{inact} = 88\%$.

- Enfin, $\eta_{SLM}^{ON} = 25\%$ est la transmission du SLM à l'état ON.

- Les derniers termes correspondent aux pertes dans le système télécentrique SLM/PUCE.

5.2.2 Inéquation pour le bras B.

Les pertes optiques sont plus importantes pour le bras (B) (boucle de rétroaction), puisque le réseau de Dammann est disposé entre les doublets L_2 et L_3 . Le facteur d'atténuation globale s'écrit alors (pour un voisinage v aux 4, 8 ou 12 voisins) :

$$\eta_{B-v}^{ON} = \eta_{D-f} \cdot \eta_f \cdot \eta_{Lb} \cdot \frac{\eta_{C2}}{2} \cdot \eta_{L2} \cdot \eta_{vign} \cdot \eta_{rep} \cdot \eta_{inact} \cdot \eta_{SLM}^{ON} \cdot \eta_{L2} \cdot \eta_{C2} \cdot \eta_{CGH-v} \cdot \eta_{C3} \cdot \eta_{L3}$$

5.3 Choix des diodes laser.

L'application numérique donne pour le bras A : $\eta_A^{ON} = 1,04 \cdot 10^{-7}$; finalement l'inéquation fixant la puissance optique de la source optique A s'écrit :

$$P_A (\text{mW}) \geq 4,8 \cdot 10^{-3} \cdot F_B (\text{Hz}) \quad (\text{I.A})$$

Pour une fréquence $F_B = 2 \text{kHz}$ (cadence maximale du SLM), il faut donc une source (A) telle que $P_A \geq 9,6 \text{ mW}$. De même, pour le bras B fonctionnant à la cadence maximale $F_B = 2 \text{kHz}$, on a :

Taille du voisinage	Atténuation globale du bras B (η_B^{ON})	Puissance P_B requise (mW)
4	$1,72 \cdot 10^{-8}$	≥ 58
8	$9,5 \cdot 10^{-9}$	≥ 105
12	$7,8 \cdot 10^{-9}$	≥ 128

⁵⁷ ce qui correspond à une aire d'un peu plus d'un pixel de côté, *mais pas deux* : c'est pourquoi $n_1=1$, et l'on choisit un "rebord" d'un pixel ($B=1$), ce qui conduit à des macropixels 3x3.

Nous avons choisi le même type de diode laser que ce soit pour la source (A) ou (B). Il s'agit d'une diode laser CW à multiples puits quantiques Philips CQL-802 de 100 mW de puissance maximale et de longueur d'onde nominale 680 nm (c'est la longueur d'onde qui maximise le contraste des SLM). L'angle de divergence en champ lointain est de $8^\circ \times 35^\circ$. Le courant de seuil est de l'ordre de $I_{th}=100$ mA, et le courant à 100 mW est égal à $I_{op}=200$ mA ($V_{op}=2,4$ V). Il serait intéressant de pouvoir contrôler ces sources à travers l'ordinateur hôte, ce qui permettrait d'automatiser la tâche de mise en route de l'expérience (cf. Ann.D, §3). Le programme est prêt, mais il restera à mettre en œuvre une carte d'entrée/sortie analogique stabilisée capable d'alimenter les diodes laser (la carte analogique PCI-428W - fig.V.24 - délivre un courant maximal de 10mA). A ce jour, le contrôle de la puissance des diodes laser sources est fait manuellement (source stabilisée Hameg HM8040).

5.4 Uniformité d'éclairement système Diode/Fibre/SLM.

L'ouverture numérique de la fibre plastique ($ON=0,5$) permet d'envisager un couplage direct entre celle-ci et la diode laser. En principe, la plus grande partie de l'énergie de la diode laser est concentrée sur un seul mode gaussien de divergence en champ lointain ($8^\circ, 35^\circ$) (voir section suivante). Ce mode excite plus ou moins fortement chaque mode propre de la fibre optique (il en existe un grand nombre pour une fibre de grande ouverture numérique). Au bout d'un trajet plus ou moins long, l'énergie va se redistribuer uniformément entre les modes et on aura à la sortie de la fibre une image de speckle uniforme. Cependant, la fibre optique plastique mesure à peine 1 m de long (pour éviter une trop forte atténuation). Il se peut alors que les différents modes excités ne soient pas parfaitement mélangés [Brenne98]. Il y aura alors à la sortie de la fibre une série d'anneaux concentriques plus ou moins lumineux correspondant aux modes les plus excités. Pour ne pas avoir à allonger trop la fibre, on a préféré lui donner une certaine courbure, ce qui s'est avéré suffisant pour rendre la sortie uniforme.




Fig.V.23 : Distribution d'énergie lumineuse à la sortie du système télécentrique (unités arbitraires). En pointillées, la taille du SLM ($\sim 4 \times 4 \text{ mm}^2$). Sur les bords haut et bas du modulateur, il y a jusqu'à 30% de moins d'énergie lumineuse qu'au centre.

Nous avons mesuré l'uniformité d'éclairement produit sur le SLM par le montage télécentrique fibre-SLM du bras "critique" B à l'aide d'un profilomètre (BeamAlyzer de Melles-Griot). On constate des défauts d'éclairement relativement importants concentrés

sur les bords du modulateur (fig.V.23). Nous avons amélioré quelque peu l'uniformité en additionnant un filtre de polarisation à la sortie de la lentille boule (la séparation des polarisations par le CSP ne semble pas très bonne pour des incidences obliques, et cela est en partie une des raisons des problèmes d'éclairage sur les bords du SLM).

Les défauts d'éclairage peuvent affecter la qualité du recuit et produire des artefacts localisés sur les bords. Nous avons procédé à une mesure directe des conséquences des défauts d'éclairage sur les probabilités de mise à jour locales au Chap.VI.§2.1.

6. Interface et cartes électroniques

6.1 Interface électronique.

La fig.V.24 est un schéma de l'électronique du démonstrateur. Le système électronique comporte trois cartes d'entrée-sortie commerciales et trois cartes-interface réalisées au laboratoire :

- une pour le contrôle de la puce SPIE600 (J.C.Rodier) ;
- une autre pour le contrôle *direct* des deux modulateurs de Displaytech sans passer par le Driver Displaytech SliM-II (carte conçue et réalisée par A.Villing). Il est important d'interfacer *directement* les SLMs avec l'ordinateur car le driver SliM-II ne permet pas une véritable rétroaction du champ d'étiquettes (bouclage rapide), ni une mise à jour temps réel du champ binaire de contrainte (bouclage lent). En effet, les séquences d'images affichées sur le SLM doivent être pré-enregistrées dans la mémoire du driver ;
- et une autre encore pour le contrôle de la puissance du laser de speckle (Ph.Lalanne).

6.2 Interface informatique pour le démonstrateur

Nous avons réalisé une interface informatique pour le PPOS totalement transparente à l'utilisateur. Celui-ci dispose d'un certain nombre de routines écrites en C et C++ et compilées sous Matlab (MEX files) pour en faire des DLL (Dynamic Library) directement exécutables sous le *prompt* (>>) de Matlab. Au chapitre III nous avons évoqué le problème du Verre de Spin (Chap.III,§6.1). Avec le nouveau dispositif expérimental, il est possible de réaliser des opérations plus "complexes" comme la restauration d'images binaires ou la détection de mouvement. On peut également choisir la topologie du voisinage (en changeant le réseau de Dammann)⁵⁸. On pourra trouver

⁵⁸ La distribution de *quatre* signaux d'horloge (quadri-coloriage) dans le cas d'un voisinage d'ordre 2 est seulement *simulé* sur SPIE600 : on lit le contenu de la puce, on fait une mise à jour des sites noirs (resp. blancs), on récupère le résultat et on remplace les sites qui n'auraient pas dû être mis à jour par leur valeur précédente (l'opération est répétée deux fois), avant de recharger le champ d'étiquettes sur la puce. La commande est *Update_4* (cf. Ann.D).

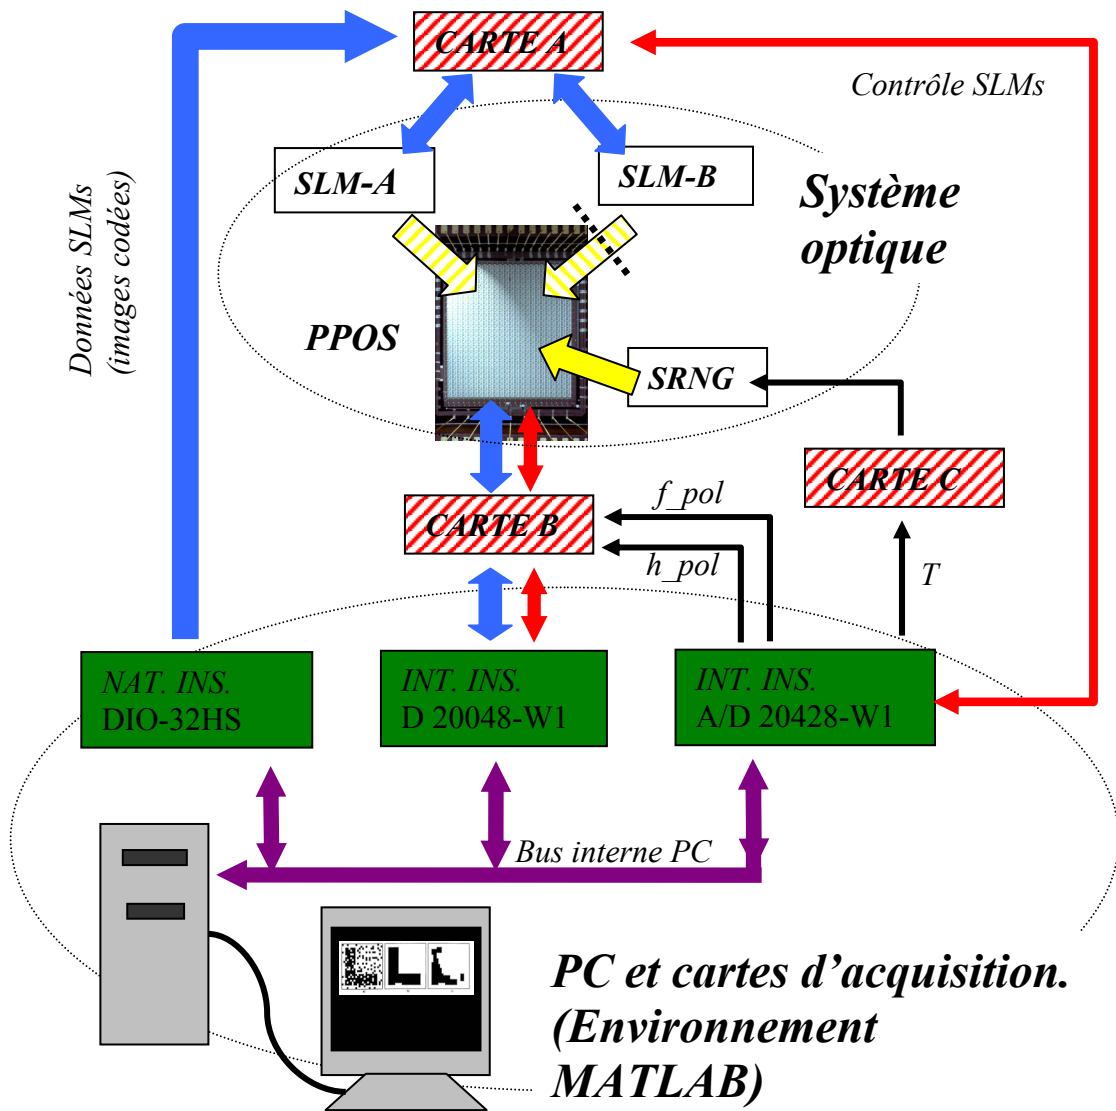
quelques extraits de code dans l'Ann.D (§4) ; les séquences de démonstration sont présentés au Chap.VI, §5.

7. Conclusion

Nous avons donc conçu et réalisé un premier prototype de démonstrateur optoélectronique utilisant le processeur optoélectronique stochastique SPIE600. Les *photos.V.1* et *V.2* donnent une idée de l'ensemble du montage optomécanique (ne sont pas représentés le montage optique générateur de speckle laser ni la partie électronique).

La rapidité (ou la qualité) du recuit est fonction directe de la cadence de mise à jour du champ d'étiquettes - et donc des performances de la boucle de rétroaction optoélectronique. Pour ce premier démonstrateur, on a choisi d'utiliser des modulateurs à cristaux liquides binaires ferroélectriques sur circuit intégré (CLF/CI) - *cf.* Ann.A. L'utilisation du composant à cristaux liquides limite les performances globales du démonstrateur : le temps de rafraîchissement minimal est de l'ordre de 0,3 ms, ce qui permettrait d'atteindre une cadence de 3 recuits sérieux par seconde⁵⁹. Nous allons valider le démonstrateur et évaluer ses performances au chapitre suivant

⁵⁹ Le recuit sérieux défini au Chap.II sert d'étalon pour la comparaison des prototypes (voir Chap.VII). Cependant, pour la démonstration du débruitage d'images 24x24, une centaine d'itérations semble suffisante pour atteindre un "bon" minimum de l'énergie. On pourrait atteindre alors une cadence de recuit de 30Hz, un peu plus supérieure à la cadence vidéo. C'est sur cette idée que l'on était parti ; mais l'interface électronique-informatique de la boucle "ne suit pas" (*cf* chapitre suivant et Annexe D).



Signaux digitaux

↔ Signaux de contrôle

↔ Bus de données

→ Bus optique binaire

Signaux analogiques

→ Signal analogique

→ Bus optique analogique

Autres symboles

⋯ Hologramme de convolution

CARTE Carte électronique commerciale

CARTE Carte électronique maison

SLM # Modulateur spatial de lumière

SRNG Générateur de nombres aléatoires optiques

Fig.V.24 : Schéma électronique de l'expérience.





Photo.V.1 : Le démonstrateur complet -montage (O)- comporte deux bras optiques : (A) pour l'entrée des données ; (B) pour le boucle de rétroaction. Un troisième bras optique (C) est utilisé pour faciliter l'alignement visuel des images sur la puce. La fibre optique provenant du générateur de speckle n'est pas présente.

Notations :

- Source : diode laser 100mW.
- SLM : modulateur spatial de lumière.
- CSP : cube séparateur polarisant.
- L : doublets.
- L_b : lentilles boule.






Photo.V.2 : Photographie du prototype complet. On distingue la fibre optique de sortie du générateur de speckle (RNG). Les dimensions sont approximativement 21x35x14 (cm)

Chapitre VI

Résultats expérimentaux

1. Mise en route de l'expérience

Avant de pouvoir réaliser une démonstration, il faut procéder à la mise en route de l'expérience. Celle-ci consiste d'une part à régler et à valider le montage optique décrit au chapitre précédent (système d'imagerie et de convolution), et d'autre part à régler les divers paramètres expérimentaux de contrôle du recuit et du modèle.

1.1 Réglages optomécaniques.

1.1.1 Alignement visuel.

Un système optique comportant deux doublets (bras replié C de la photo *Ph.V.1*) fait l'image de la puce sur une caméra CCD. On peut ainsi procéder à l'alignement des images projetées par chaque SLM sur la grille de photodétecteurs de la puce SPIE600, grâce à des vis micrométriques (contrôle en translation et en rotation et réglage du grandissement optique) -voir *fig.VI.1*.




Fig.VI.1 : Image codée en mode double-voie et projetée par un SLM sur la puce, respectivement avant et après alignement (image CCD).

1.1.2 Alignement indirect.

L'alignement visuel, quoique précis sur chaque photodétecteur individuel, doit être complété par un contrôle continu du résultat de l'alignement sur *l'ensemble* de la matrice ; la procédure consiste à couper les interactions électriques ($f_{pol}=0V$), réaliser une unique mise à jour du champ d'étiquettes en absence de speckle optique et enfin, lire le résultat de la mise à jour pour une séquence de test ligne par ligne. Dans ces conditions, la puce se comporte comme un "capteur" d'images (binaires et codées en mode double-voie, *fig.V.11*). La procédure d'alignement est effectuée successivement sur les deux SLMs, (*fig.VI.2*).



Fig.VI.2 : Extrait de la séquence d'alignement pour un réglage réussi (scan sur les lignes).

La même procédure peut être utilisée pour centrer le champ de speckle sur la puce - cette fois-ci, en absence d'image codée (voir *fig.VI.3*).



Fig.VI.3 : faisceau du générateur de nombres aléatoires, avant centrage. On remarque la section circulaire du champ de speckle, à l'intérieur de laquelle les étiquettes prennent des valeurs aléatoires.

1.2 Boucle de rétroaction.

Le réglage de la boucle de rétroaction constitue la partie la plus délicate de la mise en route : un très léger défaut de réglage compromet de façon considérable la régularité spatiale du système de voisinage. Il faut que l'alignement entre le SLM-B et la puce soit le plus précis possible *avant* l'adjonction de l'hologramme de convolution ; il faut ensuite procéder à l'alignement (en rotation) de ce dernier.

La *fig.VI.4* représente le bruit de canal sur les 24x24 ports optiques en mode double voie, pour le bus optique SLM-Puce du bras A et du bras B *sans* hologramme de convolution, pour un courant d'alimentation de 155 mA et 145 mA respectivement (légèrement en dessus des seuils laser respectifs). Le taux d'erreur est calculé en affichant une image binaire aléatoire codée en mode double-voie sur le SLM, puis en comparant celle-ci avec le résultat d'une "acquisition" sur SPIE600 (programme *Test_Bus.m*, Annexe D). La cadence de fonctionnement du bus reste très faible pendant le test (de l'ordre de 15 Hz), puisqu'il faut à chaque fois générer une image aléatoire, l'afficher,

acquérir le résultat de la mise à jour et réaliser la comparaison entre l'image originale et l'image acquise. Le bruit de canal est fonction - entre autres - de la puissance des sources laser et du temps d'intégration des photodétecteurs (et donc de la cadence de fonctionnement de la boucle de rétroaction). Nous n'avons pu constater aucune erreur de recopie et cela sur aucun port pour des courants d'alimentation des diodes laser I_A et I_B supérieurs à 160 mA et 150 mA respectivement (pas d'erreur après 15000 itérations - plus d'un quart d'heure de fonctionnement continu). Enfin, une caractérisation plus




Fig.VI.4 : bruit de canal sur les ports des bus optiques binaires (codage en double-voie) du bras A (à gauche) et du bras B sans hologramme de convolution (à droite). L'alimentation des sources optiques (155mA et 145mA) est à peine au dessus de leurs seuils laser respectifs (150mA et 140mA). Pour des courants supérieurs à 160 mA, nous n'avons pu constater aucune erreur après plus de 15000 itérations.

approfondie du bus optique ne nous est pas paru indispensable, étant donnée la nature par essence *stochastique* du processus de calcul.

La fig.VI.5 montre trois exemples de résultat de convolution optique en utilisant un hologramme d'interconnexion aux 4 et aux 8 plus proches voisins respectivement. L'image affichée sur le SLM-B (et convoluée par le réseau de Damman) est constituée d'une grille régulière de macropixels codant un ensemble PEs figés dans l'état +1 ; le reste des macropixels est "éteint" (ce qui ne correspond pas à un état "normal" du PE) pour ne pas interférer avec la visualisation immédiate du voisinage résultant de la convolution. Pour éviter le basculement aléatoire des PEs qui ne reçoivent aucun signal, le deuxième modulateur (le SLM-A) projette une image fixe codée cette fois-ci en mode double voie et correspondant à une contribution *négative* sur l'ensemble des PEs de la matrice (l'éclairement doit être moins intense que l'ordre intéressant le plus faible de l'hologramme). Les différences d'uniformité d'éclairement entre les deux SLMs contribuent certainement à la "malformation" des voisinages (phénomène plus important sur les bords de la matrice). On constate aussi que la superposition des quatre ordres

$(\pm 2, \pm 2)$ dans le cas du 8-voisinage est suffisamment intense pour faire basculer l'étiquette à +1, là où elle devrait rester égale à 0.

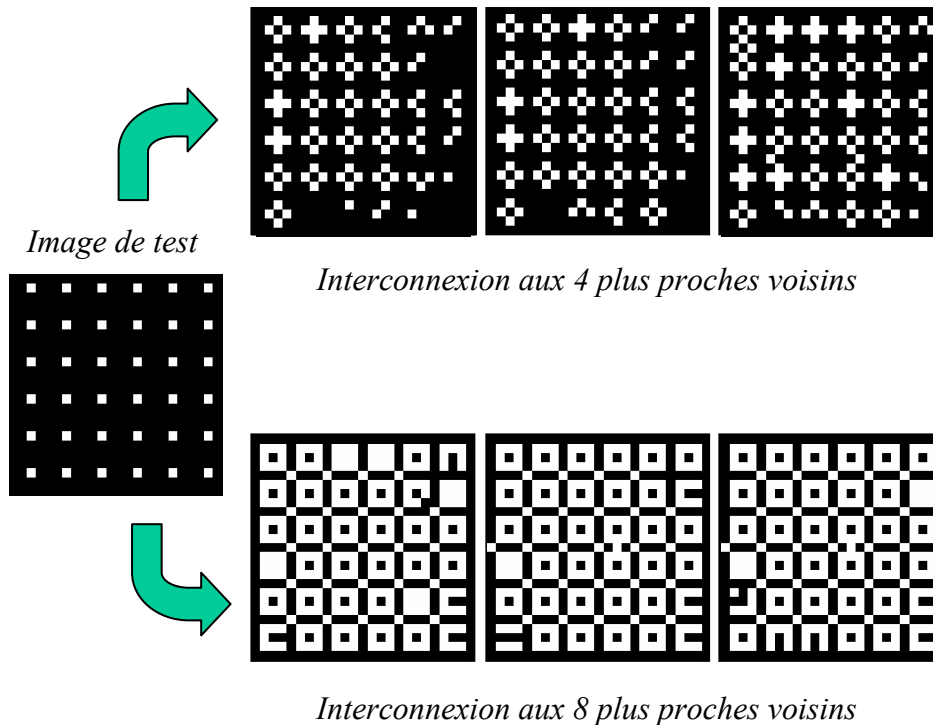



Fig. VI.5 : Trois exemples de résultat de convolution optique (bras B) sur une image de test (SLM-B), pour un hologramme d'interconnexion aux 4 plus proches voisins (haut) et aux 8 plus proches voisins (bas). Chaque "point" de l'image de test correspond à un macropixel 3x3 du SLM.

La fig. VI.6 montre le résultat de plusieurs essais de la boucle de rétroaction, à partir d'une image (également non codée en mode double-voie), correspondant cette fois-ci à un *seul* macropixel central allumé. Les défauts du voisinage se traduisent alors par la rupture de la symétrie et de la régularité du domaine en croissance.

Eviter les défauts de la structure de l'interconnexion impliquerait un montage optique plus sophistiqué ; ces défauts sont donc inévitables avec le système d'imagerie élémentaire de notre démonstrateur. Cependant, que la structure de l'interconnexion soit ou non parfaitement invariante par translation ne devrait pas affecter énormément le résultat final de la régularisation (*cf.* remarque 1 au §1.3.2) pourvu que la convolution réalise un véritable *voisinage* autour de chaque PE - ce qui semble bien être le cas, en tout cas pour les PEs se trouvant près du centre de la matrice.



(a) : deux séries d'essais de la boucle optoélectronique, pour le 4-voisinage



(b) : deux séries d'essais de la boucle optoélectronique, pour le 8-voisinage.

Fig.VI.6: Essais de la boucle optoélectronique avec hologramme d'interconnexion. L'image de départ (non représentée) correspond à un unique macro-pixel allumé.

1.3 Ajustement des paramètres

On se propose ici de déterminer le lien entre les paramètres théoriques et les grandeurs expérimentales de contrôle, tant pour la procédure de recuit simulé (en particulier la température algorithmique T)⁶⁰ que pour les paramètres du modèle de détection du mouvement. Les relations - représentées par des tableaux de correspondance - seront connues de l'ordinateur pilote, ce qui permettra de mieux régler le recuit optoélectronique grâce à la connaissance des valeurs appropriées issues de la simulation (Chap.II.,§2.2.3).

⁶⁰ le facteur de décroissance de la température $r < 1$ et le nombre de mises à jour par palier de température $nscan$ sont bien sûr des paramètres fonctionnels du recuit, directement contrôlés par le programme.

1.3.1 Description des paramètres de contrôle.

a) Paramètres du modèle. L'expression générale de la force locale au site s est :

$$F(s,t) = (\beta_S^{optique} + \beta_S^{elec}) \sum_{r \in V(s)} (2.e(r,t) - 1) + \beta_C (2.e(s,t) - 1)(2.\delta(s,t) - 1)$$

Dans le premier terme de la formule (terme de régularisation spatiale) se trouvent mélangés des contributions d'origine *optique* et des contributions d'origine *électrique* (à condition de ne pas couper les interactions électriques entre PEs). Au sein de chaque processeur élémentaire, ces différentes contributions sont représentées par des courants électriques. Si l'on garde l'expression ci-dessus pour exprimer cette fois-ci le *courant* $I_F(s,t)$ représentant la force locale, alors les divers paramètres du modèle (ou *poids* des différentes contributions à la force locale) β_S^{elec} , $\beta_S^{optique}$ et β_C sont également homogènes à des courants électriques (au Chap.III, §5.2, le paramètre β_S^{elec} était noté I_S). Chacun de ces paramètres est contrôlé de façon directe ou indirecte par une source *électrique* indépendante :

- Le poids β_S^{elec} de la connexion électrique est contrôlé directement par la tension de commande du plot f_pol de SPIE600. Celle-ci varie typiquement entre 0 et 500 mV.
- Le poids de la connexion optique $\beta_S^{optique}$ est contrôlé indirectement par le courant d'alimentation de la diode laser B du bras optique de convolution. Ce courant, que l'on notera I_B , varie entre 0 et 215 mA (la diode est protégé par un limiteur de courant), mais la diode commence à "laser" seulement vers 140 mA.
- Enfin, le poids β_C de la force de rappel aux données - d'origine exclusivement optique - dépend indirectement du courant d'alimentation de la diode laser A. Ce courant, noté I_A , varie entre 0 et 230 mA, mais la diode commence à laser vers 150 mA.

b) Paramètres du recuit. La température algorithmique T dépend des caractéristiques géométriques du montage générateur de nombres aléatoires -i.e. le nombre M des grains de speckle sur chaque photodétecteur- et aussi de l'intensité moyenne $\langle I \rangle$ du speckle. Le paramètre M est fixé une fois pour toutes ; l'intensité moyenne de speckle dépend de la tension de commande Vd de la diode laser de speckle. La température algorithmique T est également représenté par un courant (*cf.* Chap.III, §5.3.2).

1.3.2 Estimation des paramètres.

Pour établir la correspondance entre les paramètres théoriques (β_S^{elec} , $\beta_S^{optique}$, β_C , et T) et les grandeurs expérimentales de contrôle (f_pol , I_A , I_B , et Vd), nous n'avons pas mesuré directement les courants électriques correspondant à chaque terme de la force locale (ce qui n'est effectivement possible que sur *un seul* site de test de la matrice) ; nous avons employé une méthode indirecte, basée sur la caractérisation du fonctionnement *a posteriori* du processeur. Ramenons d'abord tous les paramètres à une unité arbitraire de courant donné par $\beta_0 = \beta_S^{elec}$ quand f_pol est fixé à 100mV par exemple (l'unité β_0 est

alors de l'ordre de 0,2 μA). Ce choix arbitraire est possible car un facteur d'échelle sur tous les paramètres du modèle *en plus* de la température algorithmique n'a pas d'influence sur le résultat de l'optimisation : le rapport $I_F(s)/T$ ne change pas, or c'est lui qui détermine la dynamique d'évolution à travers la loi du thermostat :

$$\Pr[e(s) = 1] = \frac{1}{1 + \exp\left[-\frac{I_F(s)}{T}\right]}$$

On procède ensuite en deux étapes -a) et b)- comme suit :

a) Tabulation des paramètres $T=f(Vd)$ et $\beta_S^{elec}=f(f_pol)$.

Temperature T en fonction de Vd . On fixe tout d'abord f_pol à 100 mV (on a alors $\beta_S^{elec}=1$ -en unités β_0). Ensuite, et pour diverses valeurs de la tension Vd contrôlant l'intensité moyenne de speckle, la procédure consiste à déterminer la matrice des probabilités de mise à jour à la valeur +1 correspondant à l'ensemble des PEs de la matrice. Le calcul est réalisé pour une force d'origine *purement électrique* ($\beta_S^{optique}$ et β_C nuls) pouvant prendre cinq valeurs distinctes (programme *Sigmoïde* dans l'Annexe D) :

$$I_F(s) = \beta_S^{elec} \cdot m = m, \text{ où } m \in \{-4, -2, 0, 2, 4\}$$

Les sites noirs et blancs sont traités alternativement ; avant chaque mise à jour, on charge sur la puce une configuration d'étiquettes et d'interactions particulière telle que la force électrique prenne tour à tour chacune des cinq valeurs possibles (les sites sur les bords sont rejetés car on ne peut pas construire toutes les valeurs possibles). On effectue ainsi plusieurs centaines de mises à jours ce qui permet de construire une matrice de probabilités locales pour chaque valeur de la force électrique. On remonte ensuite à la *matrice des températures locales* en réalisant (pour chaque site de la matrice) un ajustement entre la courbe de probabilité théorique (loi du thermostat) et les cinq valeurs de probabilité mesurées sur le site en question⁶¹. On établit ainsi une véritable *thermographie* de la puce (voir fig.VI.10). Enfin, la moyenne des températures locales sur tous les sites de la puce conduit à la courbe recherchée $T=f(Vd)$ (fig.VI.7).

Remarque 1 : *robustesse de la régularisation markovienne face à la dispersion des caractéristiques des PEs.* SPIE600 agit en "régularisant" non seulement le bruit de l'image, mais également les différents "bruits" provenant des défauts *locaux* du circuit électronique ou des imperfections du montage optique (bars A, B et générateur de speckle). On dit que le traitement markovien est *robuste* vis-à-vis des dispersions locales (i.e., dispersion des paramètres contrôlant l'évolution de chaque PE). C'est une caractéristique propre aux réseaux de neurones, étudiée dans

⁶¹ on aurait pu prendre *une seule* valeur pour la force électrique, et remonter tout simplement à la température locale en inversant la loi du thermostat ; mais l'erreur de mesure aurait été bien plus importante.

[Hutchi86] dans le cas particulier d'une rétine artificielle pour le débruitage d'images à niveaux de gris (réseau de résistances analogique) ; une étude rapide a été également menée (en simulation) sur le prototype SPIE600, consistant à rajouter des *offsets aléatoires* sur les forces locales : il semblerait alors que les effets sur le résultat final du recuit ne sont évidents (minimum de l'énergie moins profond que celui obtenu par optimisation déterministe ICM) que quand l'erreur relative sur les forces locales approche 50% [Dupre95a].





Fig.VI.7 : Mesure de la température algorithmique T en fonction de la tension d'alimentation V_d de la diode laser du générateur de speckle. (a) : probabilités de mise à jour ($\hat{a} + 1$) mesurées pour cinq valeurs de la force électrique et 20 valeurs de la tension V_d (f_{pol} est fixé à 100mV et donc $\beta_{S_elec}=1$ par convention) ; (b) : résultat de l'ajustement de la température sur chaque sigmoïde.

Remarque 2 : Pour simplifier le montage optique, on projette le *speckle laser* (issu du générateur de nombres aléatoires décrit au Chap.III,§5.3) en *biais* sur la puce (voir photographie du montage *ph.V.2*). Ceci induit un gradient spatial (sur l'axe x) de la température algorithmique. Théoriquement, celle-ci devrait évoluer de façon presque linéaire sur la surface de la puce, selon (voir *fig.VI.8*) :

$$T \propto I \propto \frac{1}{d^2},$$

or $x \ll z_o$ et x_o , donc :

$$\begin{aligned} \frac{1}{d^2} &\approx \frac{1}{z_o^2 + x_o^2} \left[1 + \frac{2x \cdot x_o}{z_o^2 + x_o^2} \right]^{-1} \\ &\approx \frac{1}{z_o^2 + x_o^2} - \frac{2x \cdot x_o}{(z_o^2 + x_o^2)^2}, \end{aligned}$$

soit :

$$T = ax + b$$




Fig.VI.8 : Le champ de speckle est introduit hors-axe. On a $z_o \approx 6\text{cm}$ et $\alpha \approx 30^\circ$.

Nous avons pu estimer les paramètres a et b de l'équation ci-dessus en moyennant sur les lignes de la matrice des températures locales car en principe il n'y a pratiquement pas de gradient spatial sur les colonnes. On a : $a = -0,04\text{mm}^{-1}$ et $b = 1,38$ avec un écart type⁶² égal à $\sigma = 0,026$. Le gradient lent de température reste relativement faible par rapport aux fluctuations rapides dues à la dispersion des éléments de la matrice (voir *fig.VI.10*).

Par ailleurs, il serait intéressant d'étudier plus en détail le processus de recuit avec gradient spatial de température (constitue-t-il un moyen d'accélérer le recuit?) ; le problème n'est pas sans rappeler la technique de purification des barres de silice destinées aux wafers pour circuits intégrés, par anneau chauffant électromagnétique. Le déplacement lent de l'anneau recuit les défauts locaux de structure et entraîne les impuretés vers une extrémité de la barre, extrémité qui sera tronqué par la suite. Il existe un gradient spatial de température sur la barre (voir *fig.VI.9* ci-contre). Nous avons procédé à quelques simulations sur le recuit pour la restauration d'images binaires ; la conclusion (rapide) semble être que tant que la variation maximale de la température sur la puce reste de l'ordre du pas entre les paliers de température au voisinage de la température critique $(1-r) \cdot T_c$, alors le résultat du recuit semble inchangé. Dans le cas contraire on devine parfois la direction du gradient dans l'image finale - qui est scindé en une région "chaude" et une région "froide" (surtout si le recuit est rapide).




Fig.VI.9 : recuit d'une barre de silicium par anneau chauffant électromagnétique.

⁶² L'écart à la loi linéaire correspond à la dispersion des caractéristiques des photodétecteurs.

Thermographie de la puce (sur 22 lignes et 22 colonnes).

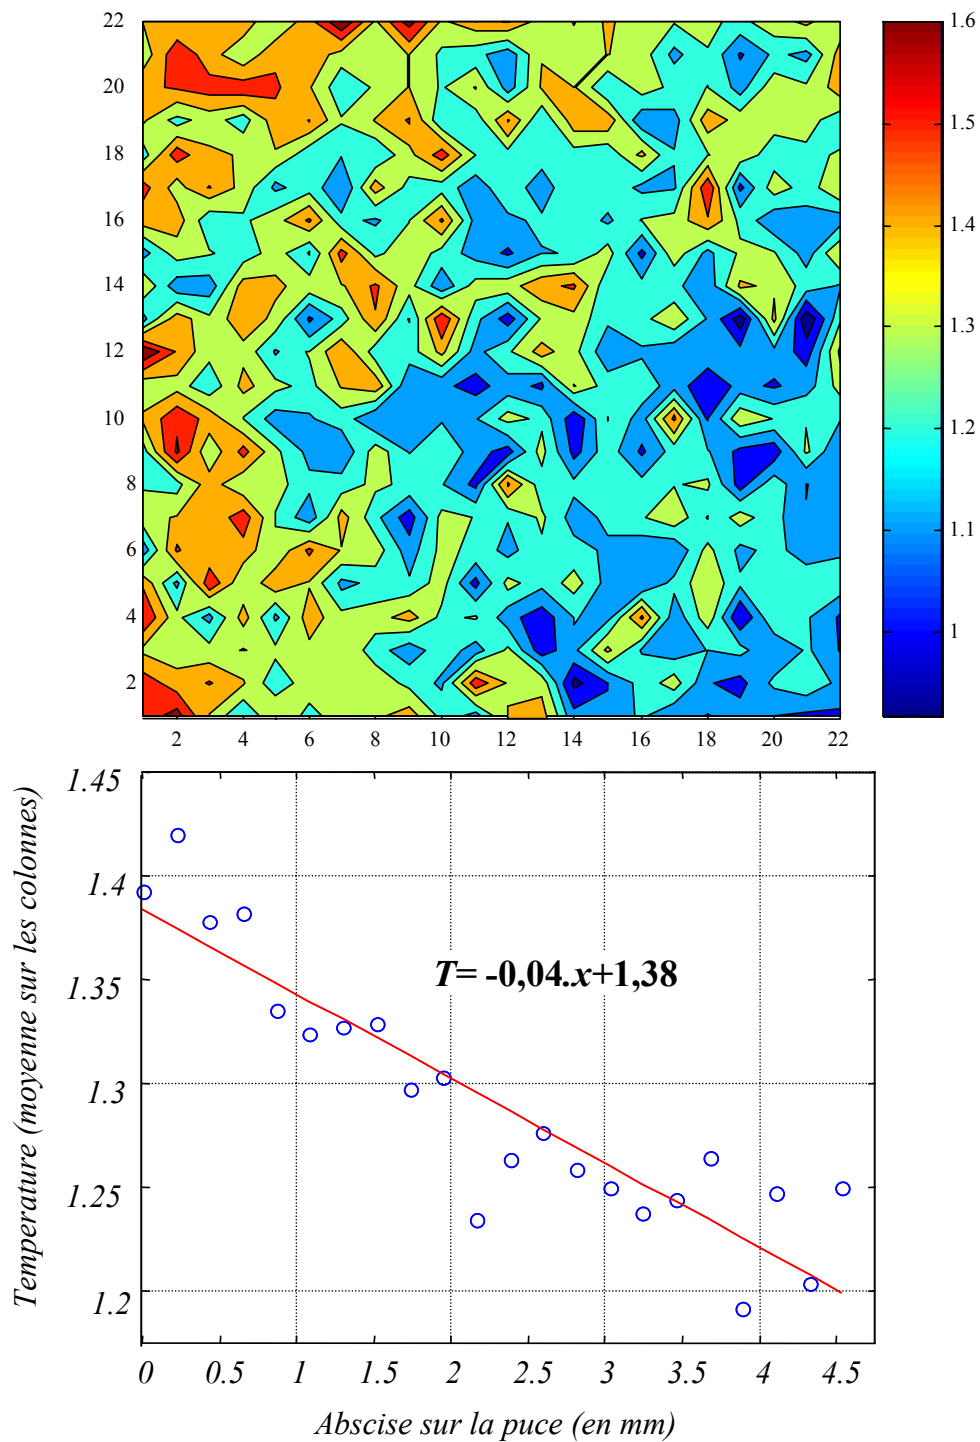


Fig.VI.10 : Thermographie et gradient spatial de température à la surface de la puce. On a fixé $V_d=2V$ (la température moyenne vaut alors $\langle T \rangle = 1,29 \pm 0,14$).

Paramètre β_S^{elec} en fonction de la tension f_{pol} . On fixe ensuite l'intensité du speckle (paramètre $Vd=2V$) : la température est fixée ($T \approx 1,3$). On procède alors de la même façon que précédemment, le paramètre variable est maintenant f_{pol} . Les valeurs de la température mesurées par la procédure décrite au paragraphe précédant correspondent cette fois-ci à $T' = T/\beta_S^{elec}$; puisque T est fixe et connue, on peut remonter à la relation $\beta_S^{elec} = f(f_{pol})$ (voir fig.VI.11).




Fig.VI.11 : Estimation de β_{S-elec} en fonction de la tension de commande f_{pol} . On a par convention $\beta_{S-elec} = 1$ pour $f_{pol} = 100$ mV.

b) Tabulation des poids "optiques" $\beta_C = f(I_A)$ et $\beta_S^{optique-v} = f(v, I_B)$ (v =voisinage).

On fixe désormais f_{pol} et Vd : T et β_S^{elec} sont donc des paramètres connus et fixés (pour simplifier on garde $f_{pol} = 100$ mV et donc $\beta_S^{elec} = 1$; on fixe la tension $Vd = 2V$, donc $T \approx 1,3$).

Poids du terme de contrainte β_C en fonction de I_A . On va comparer maintenant la contribution optique d'une image *tout à l* (codée en mode double-voie) sur le SLM-A (éclairé par la diode laser A alimentée par le courant I_A) avec chacune des cinq valeurs différentes de la contribution électrique à la force locale ($\beta_S^{optique} = 0$). Le courant correspondant à la force locale s'écrit :

$$I_F(s) = \beta_s^{elec} . m + \beta_c^{optique} = m + \beta_c^{optique} , \text{ avec } m \in \{-4, -2, 0, 2, 4\}.$$

Pour chaque valeur de m , on réalise plusieurs centaines de mises à jour du champ d'étiquettes et on obtient ainsi la matrice de probabilités de mise à jour (à +1). Par un ajustement entre la courbe sigmoïde théorique (avec cette fois-ci les paramètres T et β_S^{elec} fixées⁶³) et les cinq valeurs expérimentales de la probabilité, on peut remonter à la matrice de poids de contrainte β_C , pour une valeur du courant de contrôle de la diode laser I_A . En faisant une moyenne sur l'ensemble des sites de la matrice, on obtient la relation recherchée $\beta_C = f(I_A)$ (voir fig.VI.12 ci-dessous).




Fig.VI.12 : Estimation du poids β_C du terme de contrainte en fonction du courant de commande I_A de la diode laser source A (bras optique A).

Poids du terme de régularisation $\beta_S^{optique}$ en fonction de I_B . On procède de la même façon pour le SLM-B et le paramètre $\beta_S^{optique}$ (poids de l'interconnexion optique ou de la synapse optique) ; nous avons mesuré la contribution optique directe, avant introduction de l'hologramme (β_{S-V0}) ; à partir des mesures directes de l'efficacité dans les ordres utiles (cf. Ann.B, tab.B.1) on déduit les poids correspondants aux synapses optiques pour un voisinage d'ordre 1, 2 et 3 (4, 8 et 12 plus proches voisins respectivement, notés β_{S-V4} , β_{S-V8} , β_{S-V12}) - voir fig.VI.13.

⁶³ On n'a pas besoin de faire l'hypothèse d'un éclairage de speckle parfaitement uniforme, puisque l'on dispose de la matrice des températures locales.




Fig.VI.13: Estimation des poids des interconnexions optiques (poids des "synapses optiques"). Sans hologramme interposé : β_{S-v0} . Avec hologramme d'interconnexion aux 4, 8 et 12 voisins : β_{S-v4} , β_{S-v8} et β_{S-v12} respectivement.

1.4 Conclusion

La dynamique du poids de l'interconnexion optique $\beta_S^{optique}$ reste faible par rapport à celle du poids de l'interconnexion électronique β_S^{elec} (pertes optiques et efficacité médiocre des hologrammes de Dammann à deux niveaux de phase). Cependant, il ne faut pas oublier que le paramètre qui détermine le comportement du modèle est le rapport $\lambda = \beta_S / \beta_C$. Au Chap.II,§5.1.2 nous avons estimé qu'il faut un rapport λ entre 0,4 et 1,2 pour pouvoir traiter "correctement" le problème du débruitage d'images binaires ; la fig.VI.14 montre qu'il est toujours possible d'obtenir des valeurs de λ comprises dans cet intervalle, tant pour le système aux interconnexions électriques que pour le montage à interconnexions optiques (le domaine de fonctionnement - tension f_{pol} ou courant I_B contre courant I_A de contrôle de la source A - est compris entre les courbes de niveaux marquées 0,4 et 1,2).




Fig.VI.14 : rapport $\lambda = \beta_S / \beta_C$ et choix des paramètres :
 - (f_{pol}, I_A) pour le système à interconnexions électriques (ELEC).
 - (I_B, I_A) pour le système à interconnexions optiques (OPT).

Rem. : v = voisinage (4, 8 ou 12 voisins).

2. Démonstration

Nous avons déjà démontré la capacité du prototype à traiter le modèle du verre de spin et du débruitage d'images binaires en utilisant le voisinage électronique d'ordre 1 (*cf.* Chap.III,§6). Nous allons maintenant démontrer la possibilité d'utiliser le prototype pour traiter le problème du débruitage d'images binaires [Cassin98] et de la détection du mouvement [Cassin00] en utilisant des interconnexions *optiques* d'ordre supérieur à 1.

2.1 Débruitage d'images binaires avec voisinage optique.

Il s'agit du montage (O) utilisant des réseaux de Dammann pour réaliser les interconnexions entre PEs décrit au Chap.V. Nous avons testé le montage pour un voisinage d'interconnexion d'ordre 1 (4 voisins), d'ordre 2 (8 voisins) et d'ordre 3 (12 voisins)⁶⁴.

2.1.1 Exemple de courbes de recuit

La *fig.*VI.15 représente l'évolution de l'énergie pendant le recuit simulé, pour un voisinage holographique d'ordre 1. On vérifie bien que le minimum énergétique obtenu par recuit simulé est meilleur que celui obtenu par optimisation déterministe (ICM en utilisant toujours les interconnexions optiques)

⁶⁴ dans le cas d'un voisinage d'ordre 3, il faudrait procéder à une mise à jour parallèle sur 5 domaines de couleur distincts (*cf.* Chap.II,§2.2.5) ; d'après quelques simulations rapides, il semblerait cependant qu'un coloriage quaternaire (et même binaire!) soit suffisant pour atteindre des minimums profonds de l'énergie (voir aussi [Aarts89], §8.3.1).




Fig.VI.15 : Energie en fonction de la température pendant le recuit simulé pour le débruitage d'images en utilisant la boucle de rétroaction optoélectronique (*interconnexions optiques* aux 4 plus proches voisins).
 Comparer avec la fig.III.8 du Chap.III.

Paramètres :

Modèle : On a $I_A = 224 \text{ mA}$ et $I_B = 220 \text{ mA}$, donc $\beta_C = 1,1$ et $\beta_{S_{H4}} = 0,57$.
 Recuit : $T_i = 4,5$; $T_f = 0,005$; $r = 0,99$ et $n_{san} = 6$ (4062 itérations par recuit).
 La procédure ICM correspond à 6 mises à jour du champ avec $T = 0$.

2.1.2 Séquence de débruitage avec interconnexions *optiques*.

Les *fig.IV.16* et *fig.IV.17* correspondent respectivement à des séquences de débruitage en utilisant un voisinage optique d'ordre 1 et 2 optique. Un exemple de code pour le débruitage d'images binaires se trouve dans l'Ann.D,§4.2.

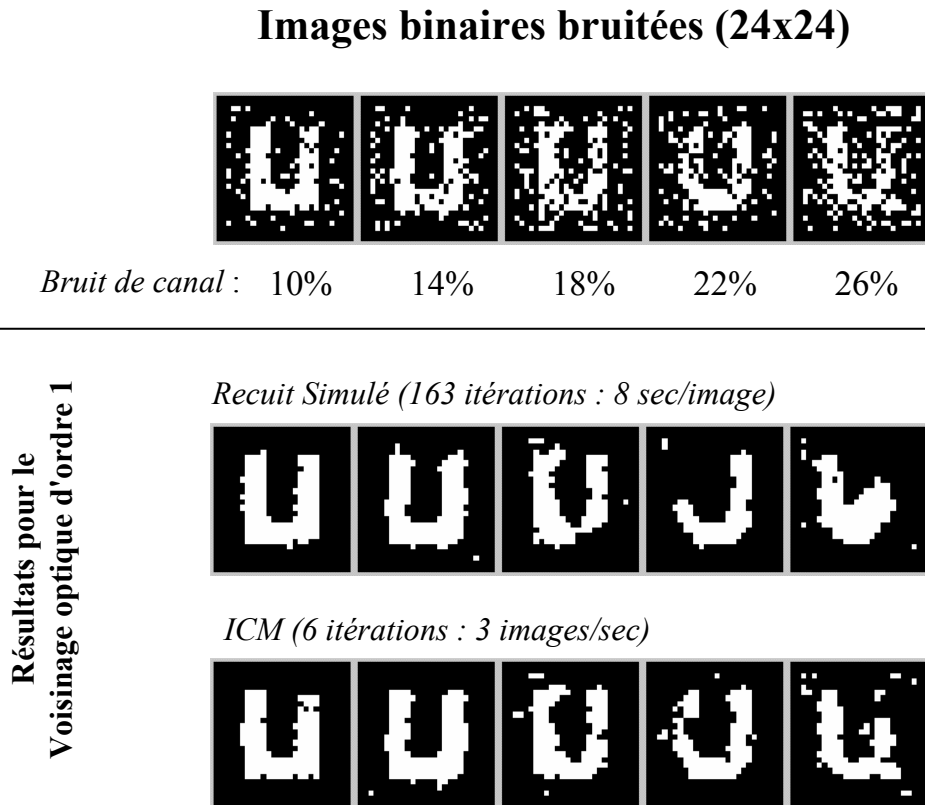


Fig.VI.16 : Débruitage d'images binaires en utilisant les interconnexions optiques, pour un voisinage d'ordre 1 (aux 4 plus proches voisins). Comparer avec la fig.III.9 du Chap.III.

Pour un bruit de canal relativement faible (de l'ordre de 15% dans la *fig.VI.15*), le résultat de la restauration en utilisant un voisinage d'ordre 2 conduit parfois à de domaines homogènes noyant les détails de l'image originale (ce qui n'est pas étrange étant donnée la faible résolution des imageries : la taille des "détails" est de l'ordre de la portée du système de voisinage).

On remarquera enfin que la restauration en utilisant un système à voisinage optique est moins sensible au problème des "frontières" rencontré pour le système à interconnexions électriques ; en particulier, il n'y a jamais de "fusion" entre l'image et les bords (*cf.* Chap.III.§6.2.4).

Images binaires bruitées (24x24)



Bruit de canal : 9,6% 10,8% 12% 13,2% 14,4%

Résultat
Voisinage optique d'ordre 2

Recuit Simulé (163 itérations : 38 sec /image)



ICM (6 itérations : 1,4 sec/image)



Fig.VI.17 : Débruitage d'images binaires en utilisant les interconnexions optiques, pour un voisinage d'interconnexion d'ordre 2 (aux 8 plus proches voisins). La cadence de traitement est de 38 s/image pour un recuit comprenant une centaine d'itérations (le quadri-coloriage pour le voisinage d'ordre 2 est simulé).

2.2 Détection du mouvement.

Comme expliqué à la fin du Chap.IV,§6.2.1, le problème de la détection du mouvement est équivalent à celui du débruitage d'un champ binaire $b(t)$ issu d'un pré-traitement spatio-temporel de la séquence originale. Pour un extrait du code informatique sous Windows-Matlab, voir Ann.D,§4.3.

La fig.VI.18 montre un exemple de détection du mouvement sur une séquence synthétique, en utilisant successivement les interconnexions électroniques de SPIE600 et les interconnexions optiques aux 4 plus proches voisins (voisinage d'ordre 1).

La qualité du résultat de la détection est excellente, ce qui s'explique d'une part par le fait que le bruit de canal n'est pas très élevé dans les séquences de mouvement (dans l'exemple, le bruit de canal de la CCT est de l'ordre de 20% - $M=40$ et $\sigma=10$, cf. Chap.IV,§6.2) et d'autre part par le fait que l'objet mobile est *rectangulaire* et que le voisinage d'ordre 1 utilisé favorise ce genre de structure. Une étude exhaustive sur diverses séquences et en utilisant des voisinages plus larges (d'ordre 2 ou 3) reste à faire,

mais l'objectif de la démonstration a été atteint. Il est aisé de vérifier en particulier que la méthode de détection du mouvement proposée donne de bien meilleurs résultats que l'estimation du mouvement par "filtre de nouveautés" (i.e., approximation de la CCT).


Paramètres de la séquence

Niveau de gris (0-255) : fond = 180 / objet = 220


Variance du bruit (gaussien) : $\sigma = 10$

Taille : Image : 24x24 / objet : 6x5

Vitesse objet : $(v_x, v_y) = (1, 2)$ pixel/image



Extrait de la séquence (une image toutes les 3)



Carte des changements temporels (CCT)



Masque binaire des objets mobiles (MB)

a)



b)



Fig.VI.18 : résultat de la détection du mouvement sur une séquence synthétique en utilisant le processeur optoélectronique stochastique SPIE600 avec (a) voisinage électronique (≈ 23 images/s) et (b) voisinage optique d'ordre 1 (≈ 8 s/image). Le recuit comprend dans les deux cas 163 itérations (mêmes paramètres de recuit et du modèle que pour les exemples de débruitage d'images binaires).

2.3 Rendu en demi-teintes ou B-codage d'images.

Compte tenu de la forme de l'énergie à minimiser dans le cas de la binarisation d'images (cf. Chap.I.§5.3), la *force locale* de mise à jour s'écrit :

$$F(s) = -\Delta U(s) = U(e(s)=0) - U(e(s)=1) \\ = - \sum_{r \neq s, r \in S} [K * K](s-r).e(r) + o(s) - \frac{1}{2}[K * K](0)$$

où e représente le champ d'étiquettes à calculer (l'image B-codée), o est l'image originelle à niveaux de gris, et K est le noyau de binarisation. Le support du produit de convolution $K*K$ détermine alors la "connectivité" entre processeurs élémentaires. Ainsi, pour un simple filtre moyenneur K de taille 3×3 aux plus proches voisins de type

$$K = \frac{1}{5} \begin{bmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \text{ le produit de convolution s'écrit : } K * K = \frac{1}{17} \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 \\ 1 & 2 & 5 & 2 & 1 \\ 0 & 0 & 2 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}, \text{ ce}$$

qui signifie que l'implémentation de l'algorithme de binarisation le plus simple (en termes de taille du noyau K) sur une machine parallèle nécessite déjà d'un voisinage d'interconnexion d'ordre 3 aux 12 plus proches voisins -zone grisée. Nous avons fabriqué l'hologramme d'interconnexion (cf. Annexe B), mais la démonstration reste à faire. Il faudrait projeter sur la puce une image à niveaux de gris (terme o de la force locale) codé au format double-voie (voir remarque Chap.VII,§4.3).

3. Conclusion

Pendant la phase de développement et de test de ce premier prototype de PPOS à interconnexions optiques, nous avons eu l'occasion de soulever un certain nombre de problèmes pratiques que nous décrirons par la suite.

3.1 Qualité du traitement.

Tout d'abord, en ce qui concerne la *qualité* du traitement, il faut reconnaître que celle-ci reste très médiocre (en particulier pour les exemples de débruitage présentés). Cependant, les modèles de *régularisation markovienne* implantés dans le démonstrateur ont été choisis par leur simplicité, et seulement dans le but de valider le *principe* du recuit simulé optoélectronique. On ne cherchera donc pas à comparer le résultat du débruitage d'images en utilisant le prototype (ni même les résultats de son émulation informatique) avec les résultats d'un traitement plus complexe et pertinent (par exemple prenant en compte le phénomène des bords ou mettant en jeu des formes de voisinage et/ou de potentiels d'interaction plus complexes). La qualité du résultat doit être appréciée uniquement en termes d'optimisation : est-ce que le minimum énergétique atteint par le PPOS est meilleur que celui résultant d'une méthode d'optimisation

déterministe (implanté sur le même prototype, ou sur n'importe quel autre support matériel), à fonction d'énergie égale? La réponse est dans ce cas affirmative. La même remarque s'applique au modèle de détection du mouvement.

3.2 Performances du prototype.

Une qualité du prototype qu'il est pourtant indispensable d'étudier (et de comparer avec d'autres machines spécialisées ou non dans le traitement d'images) est bien sûr la *puissance de calcul*. Pour un modèle donné, celle-ci pourra être indiquée par le nombre d'images traitées à la seconde, à condition de bien préciser le nombre *d'itérations* nécessaires pour traiter une seule image (car la plupart des machines de vision n'utilisent pas de techniques de relaxation stochastique).

La puissance de calcul de notre prototype dépend de la rapidité d'exécution de la boucle de rétroaction optoélectronique. Les opérations réalisées sur l'ordinateur hôte lors de cette rétroaction du champ d'étiquettes sont (dans l'ordre) :

1. Acquisition du champ d'étiquettes sur SPIE600. La lecture se fait en parallèle sur les 24 lignes. Une estimation grossière (et par défaut) de la durée de l'opération (analyse de la routine d'acquisition en C, avant compilation) donne $T_1=10^4 \times \tau_l=0,1 \text{ ms}$, où τ_l est le cycle d'horloge du processeur de l'ordinateur hôte (il s'agit d'un Pentium 100MHz, donc τ_l vaut au moins 10ns).
2. Codage du champ au format "raster" (bitmap binaire) pour être affiché sur le SLM (voir fig.V.11). Un examen de la routine C avant compilation montre que le calcul nécessite de quelques 121×10^3 opérations élémentaires pour coder une image 24x24 sur le SLM 256x256. Si l'on suppose qu'un seul cycle d'horloge est nécessaire pour réaliser chaque opération, alors la durée totale est $T_2=121 \times 10^3 \times \tau_l \approx 1,2 \text{ ms}$,
3. Chargement de l'image sur le SLM à travers la carte National Instruments DIO-32HS et la carte maison A (voir fig.V.24 au Chap.V,§6.2) ; le bus parallèle 32 bits est cadencé à 4MHz ce qui conduit à une cadence de rafraîchissement du SLM d'environ 2kHz, soit un temps $T_3=0,5 \text{ ms}$.
4. La mise à jour du champ d'étiquettes en deux coups d'horloge. Il faut pourtant, entre deux mises à jour du champ, assurer un temps "d'exposition" τ_o nécessaire à l'intégration du signal optique par les photodétecteurs de la puce. Ce temps est fonction de la puissance des sources optiques A et B ; le choix des sources réalisé au Chap.V,§5 devrait permettre d'atteindre une cadence de 2kHz pour un voisinage d'ordre 2. Le temps d'intégration vaut dans ce cas $\tau_o=0,5 \text{ ms}$. Par rapport à cette durée, le temps de mise à jour des registres de SPIE600 est négligeable (de l'ordre de 0,1µs). Finalement $T_4 \approx \tau_o = 0,5 \text{ ms}$.

La durée totale de la rétroaction optique du champ d'étiquettes est finalement de l'ordre de $\tau_{boucle}=T_1+T_2+T_3+T_4 \approx 2,3 \text{ ms}$, ce qui implique une cadence maximale pour la boucle de rétroaction égale à $F_{boucle} \approx 435 \text{ Hz}$. Cette cadence est déjà très en dessous de la cadence nécessaire pour réaliser un *recuit sérieux* à cadence vidéo (1000x25 itérations par seconde!), mais suffisante pour une démonstration de débruitage d'images ou de détection de mouvement à cadence vidéo sur des imageries 24x24 (4-9 images/seconde

pour une centaine d'itérations, cf. Chap.III.§7.2). Malheureusement, la mesure directe de la durée de rétroaction (commandes *tic* et *toc* de Matlab) conduit à des résultats encore plus décevants (quoi qu'il en soit, cette évaluation est plus pertinente puisqu'elle prend en compte la durée d'allocation et stockage des données, les interruptions Windows, etc). La routine *Boucle_Optique* (voir Ann.D) est responsable de la rétroaction complète et de la mise à jour parallèle du champ d'étiquettes. La durée d'exécution de la routine est⁶⁵ :

- pour un coloriage 2 : $\tau_{boucle} \approx 47 \text{ ms}$, donc $F_{boucle} \approx 21,3 \text{ Hz}$.
- pour un coloriage 4 (simulé) : $\tau_{boucle} \approx 238 \text{ ms}$, donc $F_{boucle} \approx 4,2 \text{ Hz}$.

Les performances du système (O) sont donc très médiocres⁶⁶. Heureusement, pour les "imassettes" 24x24 utilisées dans notre démonstrateur, il suffit de quelques 50-100 itérations au lieu de 1000 pour atteindre un minimum profond de l'énergie *meilleur* que l'ICM⁶⁷. La cadence de traitement⁶⁸ est alors de l'ordre d'une image toutes les 2 à 5 secondes pour un voisinage d'ordre 1 et d'une image tous les 12 à 24 secondes pour un voisinage d'ordre 2. Ces résultats sont à comparer avec la *centaine* d'images à la seconde en utilisant le voisinage électronique de SPIE600, Chap.III.§7.2.

Avec le démonstrateur actuel, la cadence vidéo n'est atteinte que pour un voisinage d'interconnexion électronique. Cependant, étant donné que la *cadence* de mise à jour est indépendante de la taille de l'image puisque le processeur est parallèle⁶⁹, et si l'on extrapole les résultats pour des images "réalistes" 128x128 pixels par exemple, alors il ressort que les performances du démonstrateur sont *potentiellement* compétitives avec les différentes architectures matérielles proposées dans la littérature pour implanter des algorithmes de détection du mouvement basées sur la régularisation markovienne – aucune de ces réalisations n'utilise de méthode d'optimisation stochastique.

⁶⁵ Le temps d'intégration de photodétection $\tau_o=0,5 \text{ ms}$ reste toujours inférieur au temps d'exécution de la routine de rétroaction ; τ_o peut alors être réduit à 0 pour un fonctionnement en continu de la boucle.

⁶⁶ Un facteur quatre pourrait être gagné plus ou moins aisément sur ces cadences (en utilisant la procédure décrite dans l'Ann.A, "problème de la compensation des charges", sur chacun des SLMs) ; ceci implique cependant une modification de l'électronique maison (la carte conçue par A.Villing possède un système de verrouillage de sécurité qui contrôle l'inversion des images sur les modulateurs pour éviter de les détériorer), et reste donc à faire. Pour aller au delà de ces cadences ($21,3 \times 4 = 85,2 \text{ Hz}$), il faudra revenir à l'interface DOS et réviser l'architecture électronique de la boucle. En effet, en utilisant un matériel d'acquisition et de traitement aujourd'hui à peine plus performant (par exemple un Pentium 600MHz), on peut rendre la durée de traitement et d'acquisition du même ordre que celle nécessaire pour la détection des signaux optiques sur les photodétecteurs (à 2kHz) et même inférieure ; si l'on rajoute une mémoire tampon avant les SLMs, un traitement de type *pipe-line* est concevable, ce qui permettrait d'atteindre la cadence maximale envisagée au Chap.V (2kHz pour une source laser de 100mW).

⁶⁷ le nombre de mises à jour pour le recuit reste quand même entre 10 et 20 fois plus élevé que le nombre de mises à jours correspondant à l'ICM (typiquement 5).

⁶⁸ La durée supplémentaire de 9 ms (routine *Recupere_Puce*) pour l'acquisition des résultats sur SPIE600 est négligeable par rapport à la durée du recuit.

⁶⁹ ... par contre, le *nombre* d'itérations par recuit peut dépendre de la taille de l'image -cf. Chap.II.§2.2.4.

Le *tab.VI.1* permet de comparer la puissance relative à plusieurs approches matérielles différentes pour détecter le mouvement (par régularisation markovienne de la carte des changements temporels).

Nom	Type machine	Algorithme	Performances
PC Intel Pentium120	Machine séquentielle conventionnelle (CISC).	- Lalande simplifié discret (cf. Chap.IV,§6). - Optimisation : RS (100 itérations)	Taille image : 24x24 Cadence : 0,1 im/sec.
SUN Sparc-10 [Caplie95]	Machine séquentielle conventionnelle (CISC). Système volumineux	- Dumo/Caplier - Optimisation : ICM (4 itérations)	Taille image : 128x128 Cadence : 0,5 im/sec
CNAPS [Caplie95]	Machine parallèle SIMD, 256 PEs (une ligne d'image par processeur). Système volumineux et coûteux.	"	Taille image : 128x128 Cadence : 10 im/sec
TRANSVISION (réseau de <i>transputers</i>) [Déruti91]	Machine parallèle : module pipeline vidéo (2 transputers T800 à 25 MHz) + module MIMD à mémoire distribuée (12 transputers Inmos T800) . Système volumineux et coûteux.	-modèle markovien spatial (8 voisins) à contrainte temporelle + image de référence [Bellon94] -Optimisation : ICM.	Taille image : 256x256 Cadence : 1,8 im/sec
PCMARKOV [Dumont96]	Machine non parallèle : carte de traitement d'images sur PC, VPC941 à base d'un unique DSP (ST18941). Système compact et peu coûteux.	-Dumontier-Caplier -Optimisation : ICM (4-5 itérations).	Taille image : 128x128 Cadence : 3 images/sec
"Rétine artificielle" [Luthon95]	Machine parallèle à grain fin, ASIC/SIMD (réseau de résistances sur circuit <i>analogique</i> VLSI). Composant directement intégrable sur un système optique d'acquisition ; peu coûteux si produit en masse.	-Dumontier-Caplier modifié (potentiels <i>quadratiques</i> et étiquettes continues, seuillés à la fin de la relaxation). -Optimisation : descente de gradient déterministe parallèle.	(en simulation) Taille image: 32x32 Cadence : ≈ 10 ns / image, soit 100 millions d'images à la seconde ! (cadence indépendante de la taille de l'image)
SPIE600	ASIC/SIMD (Réseau analogique et <i>numérique</i> de 24x24 PEs, interconnectés <i>électroniquement</i>). Calcul <i>analogique</i> (optoélectronique) pour la mise à jour <i>stochastique</i> (cf. Chap.III). Composant peu coûteux si produit en masse ; le générateur de nombres aléatoires pose peut être un problème d'intégration (taille d'un lecteur de CD).	-Lalande simplifié discret (cf Chap.IV). -Optimisation : RS (100 itérations)	(expérience) Taille image : 24x24 (*) Cadence : centaine d'images/sec.
Prototype PPOS utilisant la puce SPIE600	<i>idem</i> , avec interconnexions <i>optiques</i> entre PEs (montage de rétroaction <i>non</i> monolithique). Prototype encombrant (21x34x14 cm ³) à moins de rendre la rétroaction <i>monolithique</i> (cf. Chap.VII).	"	(expérience) Taille image : 24x24 (*) Cadence : $v=4$: 0,2 images/sec (5 secondes /image) $v=8$: 0,04 images/sec (24 secondes/image)

Tab.VI.1 : Performances comparés de quelques solutions matérielles pour la détection du mouvement. () la cadence de mise à jour est indépendante de la taille de l'image ; par contre la cadence de recuit peut dépendre de la taille de l'image (cf. Chap.II,§2.2.4).*

Au chapitre suivant on proposera un nouveau prototype de PPOS à entrées et sorties optiques, réduisant énormément la durée d'exécution de la boucle de rétroaction ; on verra alors qu'un tel composant laisse loin derrière les autres approches matérielles concurrentes, tout en gardant la flexibilité d'un voisinage optique reconfigurable.

3.3 Sur les interconnexions optiques en espace libre

Le système d'imagerie utilisée (système télécentrique afocal utilisant une paire de doublets - Chap.V,§2.4) est rudimentaire mais suffisant pour interconnecter la totalité des PEs de SPIE600 et la grille de macropixels correspondante dans le modulateurs spatial de lumière, sans que les aberrations de champ conduisent à rejeter certains sites de la matrice (inter-modulation ou défauts d'alignement). Un montage optomécanique plus sophistiqué ne serait justifié que si la densité surfacique de PEs était plus importante et/ou pour des matrices plus larges (système macro-optique utilisant des primes de Risley pour l'alignement, modules pré-alignés à microconnecteurs [Miyaza99], système compact à microlentilles [Glaser95], etc.).

S'il est vrai qu'en augmentant la puissance optique des sources l'erreur de canal des "bus optiques binaires" peut être rendue très faible (*cf.* §1.2, *fig.*VI.4), il ne faut pas oublier que les "données" circulant sur le circuit optique ne sont pas de nature purement "digitale" (le codage en double-voie est nécessaire seulement pour représenter le *signe* de chaque contribution à la force locale, mais les *poinds* pondérant les différents termes restent tributaires des *intensités* relatives aux signaux optiques - même si celles-ci demeurent constantes tout au long du traitement). Or, les aberrations de champ (et/ou les défauts d'alignement, *cf.* Chap.V,§2.3) induisent une *dispersion* plus ou moins aléatoire de l'éclairement sur la grille des photodétecteurs. Celle-ci, quand bien même resterait faible, est de nature à altérer de façon imprévisible le résultat du calcul *analogique* ; c'est seulement grâce à la *robustesse* du modèle markovien face aux imperfections (nombreuses) du système optoélectronique (voir remarque 1 au §1.3.2) que nous avons pu valider le principe du recuit simulé sur le PPOS (minimum de l'énergie plus profond que l'ICM). Cependant, il est possible que des traitements plus sophistiqués (comprenant par exemple un prétraitement optique des termes de rappel et/ou l'utilisation des noyaux de convolution plus larges -cas du B-codage d'images) exigent une précision *analogique* plus importante. On pourrait diminuer les erreurs de calcul en *discrétisant* les poids optiques (et encore en "numérisant" le codage optique, en augmentant le nombre de ports par PE) ; cependant, si l'on choisit de garder le principe de *calcul analogique* propre à SPIE600 (nécessaire d'ailleurs pour la génération optique de la loi probabiliste d'évolution), il sera indispensable d'améliorer la précision "analogique" du montage optomécanique. Les commentaires précédents s'appliquent en particulier aux éléments diffractifs (DOEs) constitutifs du montage optique de convolution (réseaux bidimensionnels de Dammann) : néanmoins, ceux-ci sont faciles à aligner et n'introduisent pas d'aberrations ou des dispersions supplémentaires appréciables. Par contre, il semble évident que si l'on se limite à *deux* niveaux de phase, on ne pourra pas réaliser parfaitement toutes les configurations de voisinages voulues (et on remarquera par exemple le basculement incorrect de certains PEs par accumulation des ordres parasites ($\pm 2, \pm 2$) dans le cas du voisinage d'ordre 2 – *cf.* §1.2, *fig.*VI.5).

Chapitre VII

Vers une nouvelle puce à entrées et sorties optiques.

1. Motivations.

Dans le prototype présenté au Chap.V, la réalisation de voisinages larges et reconfigurables – difficiles à réaliser par des moyens purement électroniques - passe par l'utilisation de la convolution optique. Cependant, la boucle de rétroaction proposé dans l'architecture du démonstrateur - montage optique (O) - , bien que comprenant un modulateur spatial de lumière assez rapide, place les performances globales du système très en dessous de ses possibilités théoriques. En effet, même si l'on ne tient pas compte du temps nécessaire pour la conversion du champ d'étiquettes en format image pour être affiché sur le SLM, la rapidité de la rétroaction est au moins limitée par le temps minimum de rafraîchissement⁷⁰. Cette contrainte limite le nombre d'itérations par recuit et/ou la cadence du traitement (*cf.* Chap.VI,§3.2).

Supposons maintenant que la rétroaction (i.e. l'échange de données entre PEs voisins) se fasse de façon quasi instantanée, comme c'est le cas pour le prototype (E) du Chap.V à interconnexions électriques. On peut alors cadencer le prototype de PPOS SPIE600 à sa vitesse maximale (cadence de mise à jour des PEs) qui est au moins de l'ordre du MHz [Dupret95a] ; le temps de mise à jour du champ d'étiquettes entier est tout simplement égal au rapport du nombre de couleurs à cette fréquence d'horloge. Si l'on se borne à la prescription minimale pour le recuit sérieux (1000 itérations, *cf.* Chap.II,§2.3.3) et si le coloriage est binaire (interconnexions aux 4 plus proches voisins) alors pour une horloge

⁷⁰ Cette limitation est inhérente à tout système d'adressage électronique, pour lequel un temps de traitement en gros proportionnel au nombre de pixels de la matrice est nécessaire. Tant que l'on utilise *quelque part* un bus électronique pour l'acheminement des données, on ne sera pas en mesure de démontrer correctement la capacité de traitement parallèle du processeur PPOS.

de 1 MHz, la cadence de traitement peut être bien supérieure à la cadence vidéo⁷¹. Le seul inconvénient avec SPIE600 est que le voisinage d'interconnexion (électrique) d'un PE reste limité à ses 4 plus proches voisins.

Les interconnexions *optiques* permettraient l'accès à des voisinages larges et reconfigurables *sans* compromettre les performances du processeur - à condition que le SLM puisse être remplacé par un dispositif à adressage parallèle et intrinsèquement rapide (cadence du même ordre que l'horloge de mise à jour de la matrice). Une façon de mener à bien ce projet est de pourvoir chaque PE non seulement d'entrées optiques mais aussi de *sorties* optiques, les signaux de sortie pouvant être convolués optiquement avant d'être retro-projetés sur la puce, le tout formant une *boucle de rétroaction monolithique* (cf. Chap.III,§3 et §4). Ainsi, la nouvelle matrice optoélectronique pourrait comprendre des PEs isolés électroniquement (en principe ils ne seraient aucunement interconnectés, sauf pour ce qui est de l'horloge commune et d'un éventuel système d'écriture électronique pour les signaux de contrôle - cf. §4.3).

Cette nouvelle matrice à entrées et sorties optiques rentre dans la catégorie de ce que l'on appelle *les circuits intégrés optoélectroniques* ou *OEVLSI*, et plus particulièrement dans la classe des *matrices de pixels intelligents* ou *SPA* (pour *Smart Pixels Arrays* en anglais).

2. Les circuits intégrés optoélectroniques (OEVLSI).

2.1 Introduction

Le but de ce paragraphe est de donner un aperçu d'une technologie relativement jeune mais qui n'est plus désormais confinée aux seuls laboratoires de recherche. Les circuits optoélectroniques/VLSI sont parfois appelés – à tort - *Smart Pixels Arrays* (SPA). Un SPA est effectivement une puce comportant des éléments optoélectroniques permettant la conversion des signaux optiques en signaux électriques et vice versa ; mais comme son nom l'indique, ces entrées et sorties optiques sont arrangées de façon régulière sur toute la surface de la puce. Le SPA est donc un cas *particulier* de puce optoélectronique, et il faut éviter la confusion car il n'y a aucune raison de principe pour qu'un circuit OE-VLSI soit composée d'une *matrice* de processeurs élémentaires, même différents entre eux (les éléments d'entrée-sortie optoélectroniques peuvent par exemple être regroupés en rangées quelque part dans le circuit pour venir alimenter une nappe de fibres optiques [Lukowi98] ou pour réaliser un bus optique d'interconnexion plus ou moins rudimentaire en espace libre ou grâce à des éléments optiques en plastique [Bauken99]. Néanmoins, parmi toutes les puces optoélectroniques, la géométrie des SPAs est celle qui exploite

⁷¹ Certaines parties du circuit SPIE600 ont subi des tests jusqu'à 10 MHz. Il n'y a pas d'étude expérimentale complète effectué sur SPIE600 à cette cadence ; elle donnerait lieu à des recuits sérieux à 5kHz pour un 4-voisinage et 2,5kHz pour un 8-voisinage.

théoriquement au mieux la capacité d'interconnexion des bus optiques bidimensionnels (voir paragraphe suivant). Quand la quantité et la densité de pixels de la matrice deviennent importantes, les SPA peuvent être assimilées à de véritables rétines intelligentes. En effet, par leur caractère matriciel, elles sont tout particulièrement adaptées aux problèmes de traitement d'images bas niveau ; d'un point de vue traitement d'images, certains circuits optoélectroniques sont aussi des cas particuliers de *rétines artificielles*.

Les SPA bénéficient donc du *double* effort de recherche OEVLSI / rétine artificielle. D'une part, il y a eu une importante recherche -plutôt d'avant garde- sur les rétines artificielles en technologie VLSI. Plus récemment, les efforts menés dans le domaine des interconnexions optiques entre processeurs (*intra-multi-chip-modules*, ou *intra-MCM* [Bauken99]), ou entre modules (ou cartes) électroniques (*intelligent optical backplanes* [Szyman96]) ont tous fait sentir la nécessité de trouver une interface d'entrée/sortie optoélectronique adaptée permettant de bien exploiter les possibilités offertes par les interconnexions en espace libre. Le composant définitif pourrait bien être un SPA en technologie hybride CMOS/SEED comme l'atteste une certaine convergence de la recherche dans le domaine [JTEOS99]. On exposera sobrement par la suite les motivations technologiques de cet effort de recherche sur *les interconnexions optiques en espace libre*.

2.2 Bus optique vs bus électronique

Avant d'atteindre les limites physiques ultimes de la technologie VLSI ($0,03 \mu\text{m}$ est la longueur du canal du transistor MOS au delà de laquelle l'effet tunnel devient important [Mead94]), le progrès des systèmes électroniques se verra confronté au problème des interconnexions entre différentes puces d'un même module ou carte électronique. En effet, des progrès considérables sont encore à prévoir dans le domaine des processeurs VLSI, de sorte que d'ici dix ans la bande passante (*bit rate*) d'un bus de données inter-processeur devrait être capable de supporter le **Tb(10^{12} bits)/s** [SIA97].

2.2.1 Le bus électrique

Le câblage électrique conventionnel montre alors des sévères limitations dues notamment aux effets de peau des conducteurs métalliques (atténuation aux hautes fréquences, capacités et inductances parasites). De plus, la bande passante totale d'un bus d'interconnexion électrique est proportionnelle à l'aire de sa section transversale et *inversement* proportionnelle à sa longueur totale [Miller97] ; or, les bus électriques sont pour la plupart bidimensionnels (de très faible épaisseur), tandis que leur longueur est de l'ordre de la dizaine de centimètres (distance inter-processeur). En fin de compte, on montre que la bande passante des bus électriques est limitée à la **centaine de Mb/s**, quatre ordres de grandeur en dessous du Tb/s [Smith95].

2.2.2 Le bus optique (en espace libre)

Les interconnexions utilisant de la lumière en espace libre sont une alternative possible pour atteindre le Tb/s. En effet, on peut montrer que la densité d'interconnexion optique volumique maximale ne dépend que de la longueur d'onde choisie [Ozatka90] (le nombre d'interconnexions utiles est le produit de cette densité par la surface transversale du bus optique). La bande passante totale du bus est le produit du nombre d'interconnexions par leur bande passante individuelle, et cette dernière est invariante par changement d'échelle car il n'y a pas de pertes résistives sur la longueur de l'interconnexion ni des effets de couplage entre différentes voies. Il s'ensuit que la bande passante totale du bus optique (pour une longueur d'onde donnée) est tout simplement proportionnelle à la surface transversale du bus ; la longueur du bus ne compte pas, et l'on peut réaliser des interconnexions sur les distances "considérables" inter-processeur (dizaine de centimètres).

La bande passante du bus optique entre deux puces est maximisée si sa surface transversale d'interconnexion est maximisée ; ceci est réalisé (pour une surface de composant et une densité surfacique de transducteurs optiques donnée) si l'on peut disposer de la totalité de la surface du composant pour les opérations d'entrée/sortie - i.e. sans qu'il y ait à acheminer électroniquement les données sur une partie du circuit dédié à la transduction optoélectronique. C'est *précisément* ce qui est réalisé dans un SPA.

La grande difficulté pour mettre en place un bus optique reste d'ordre optomécanique. Les principales approches pour interconnecter des SPA sont (1) les systèmes macro-optiques [Hinton94], (2) les systèmes micro-optiques utilisant des micro-lentilles réfractives ou diffractives, où chaque micro-lentille est responsable d'un seul chemin de données (*light-pipes*)⁷², ou d'un groupe réduit de canaux provenant d'un regroupement de PEs [Rolsto96] ; enfin, (3) les systèmes hybrides (macroµ-optique). On attend de cette dernière approche une réduction de la taille et du coût du système [Lohman91].

2.2.3 Conclusion.

Les interconnexions en espace libre permettent d'avoir une surface transversale d'interconnexion bien plus grande que les interconnexions électriques, pour une longueur égale ou supérieure⁷³. Pour pouvoir profiter de l'énorme bande passante résultante, l'interface -de nature *électrique*- entre le circuit VLSI électronique et le dispositif

⁷² Une autre approche "micro-optique" consiste à utiliser une fibre optique par canal, pour en faire un bus optoélectronique 1D [Lukowi98] ou même 2D [Jöhnck99] ; mais il s'agit bien sûr d'une solution en *optique guidée*.

⁷³ Il est vraisemblable que le gain en bande passante l'emporte sur les inconvénients liés à l'encombrement des bus optiques : il suffit d'imaginer le nombre de circuits imprimés nécessaires pour réaliser la même bande passante, à condition que cela reste possible (il se peut que la distance inter-processeur rende définitivement impossible l'utilisation d'un bus électronique).

optoélectronique de conversion ne doit pas constituer un goulot d'étranglement. La bande passante limitée des connexions électriques implique alors une disposition particulière des éléments de transduction optoélectronique : ils doivent être placés le plus près possible des sorties électriques, et tout bus électrique intermédiaire est à proscrire. La technologie d'interconnexion par *flip-chip-bonding* (voir §2.3.1) permet justement de réaliser des interconnexions surfaciques, pour lesquelles la distance d'interconnexion électrique est de l'ordre de la dizaine de microns (taille du plot métallique) et la surface transversale est exactement celle de l'interconnexion optique⁷⁴.

2.3 Les Matrices de Pixels Intelligents (*Smart Pixels Arrays*)

2.3.1 Introduction

Une matrice de processeurs optoélectroniques élémentaires ou *SPA* est donc une structure bidimensionnelle composée de circuits électroniques (CMOS, BiCMOS, bipolaire, etc.) et des unités de sortie et/ou entrées optiques (*fig. VII.1*). De tels dispositifs peuvent communiquer par le biais d'interconnexions en espace libre. Dans le cas le plus simple, ces matrices sont composées de *processeurs élémentaires* (*PE* - ou *SP* pour *Smart Pixel* en anglais) identiques et disposés régulièrement⁷⁵ sur la surface de la puce. Chaque processeur élémentaire est composé d'entrées et/ou sorties optiques et d'une unité de traitement digital allant d'une poignée de transistors pour assurer un simple gain non-linéaire, jusqu'à plusieurs milliers capables par exemple de reconnaître et de traiter les entêtes de paquets ATM dans le cas du routage par voie optoélectronique [Davenp96]. Une discussion basée sur un bilan énergétique en tenant compte des paramètres technologiques actuels place l'optimum de "l'intelligence des pixels" aux alentours de 100 portes logiques par port optique [Desmul99].

Enfin, des interconnexions électroniques plus ou moins complexes entre différents PEs ainsi que des signaux de contrôle (programmation, horloge) peuvent aussi venir encombrer le circuit. La bande passante du bus électronique de données est supposé être de l'ordre de celle puces électroniques actuelles (<10Gb/s). La fonction d'entrée optique est assurée par des dispositifs optoélectroniques de détection tels que les photodiodes P-

⁷⁴ La technique de *flip-chip bonding* (ainsi que d'autres techniques comme par exemple le *Active Interconnect Packaging* [Kaloye97]) peut être utilisée pour interconnecter directement des circuits intégrés électroniques (on parle de technologie *3D*, *z-plane* ou *WSI* pour *wafer scale integration* - voir par exemple [Little88], [Carson89], et plus récemment [Furuya97]). Ainsi, en empilant côte à côte les différents circuits intégrés on peut résoudre le problème du goulot d'étranglement entre puces. Néanmoins, les très faibles distances d'interconnexion réduisent la capacité de dissipation thermique du composant ; en outre, il est impossible d'interconnecter des puces éloignées, ni de réaliser des schémas d'interconnexion non-locaux et/ou reconfigurables, grande spécificité des liaisons optiques en espace libre (multiplexage spatial ou *SDM* pour *space division multiplexing* : *Banyan networks*, *perfect shuffle*, etc. [McAula91]). Ce n'est donc pas une technique directement concurrente pour les interconnexions optiques en espace libre.

⁷⁵ On peut regrouper les ports optiques dans le but de réduire l'ouverture numérique et faciliter la conception du système d'imagerie [Rolston96].

I-N de type MQW (à multiples puits quantiques) ou MSM (*métal-semiconducteur-métal*). Le photodétecteur est souvent associé à un étage électronique d'amplification pour rendre le signal accessible au traitement digital. Quant à la sortie optique, elle peut être réalisée grâce à des composants actifs (LEDs ou VCSELs) ou passifs (modulateurs à multiples puits quantiques, cristaux liquides, etc.). L'avantage des dispositifs passifs est la faible consommation et donc également la faible dissipation thermique sur la puce ; par contre il faut une source de lumière externe, ce qui accroît la complexité de l'optomécanique associé.

La bande passante du bus optique ainsi constitué peut en principe dépasser la centaine de Gb/s. La bande passante individuelle d'un composant de type VCSEL ou CMOS-SEED est de l'ordre du Gb/s : il suffirait donc d'une matrice de 30x30 de ces éléments pour atteindre le Tb/s. Des démonstrateurs existent déjà qui réalisent une bande passante optique de l'ordre du Tb/s [Walker99].




Fig.VII.1 : Dans une matrice de pixels intelligents (Smart Pixel Array), la bande passante du bus optique est beaucoup plus grande que celle du bus électronique.

2.3.2 Quelle technologie pour les SPAs?

Dans le courant de la décennie, plusieurs composants (et technologies associées) ont été développés pour réaliser des circuits OEVLSI à entrées et sorties optiques. Nous passons en revue rapidement quelques unes des diverses approches pour nous arrêter sur une technologie très prometteuse et sur laquelle s'est porté notre choix pour le futur démonstrateur, à savoir la technologie d'hybride CMOS/SEED par *flip-chip-bonding*.

2.3.2.1 Matrices de pixels intelligents modulant la lumière.

Les matrices optoélectroniques intégrant des détecteurs et de *modulateurs* de lumière ont été les premières à être développées. Il s'agit de composants technologiquement assez bien maîtrisés (faible dispersion des caractéristiques et rendement de fabrication élevée). La source de lumière est externe, ce qui peut constituer un avantage pour synchroniser le fonctionnement des PEs, mais implique un montage optique plus complexe.

-Modulateurs à cristaux liquides sur CI. Les composants CL/CI (ou LCOS pour *liquid-crystal-on-silicon*) sont des circuits intégrés sur silicium formés de pixels ayant un peu d'électronique (et éventuellement des photodétecteurs), sur lesquels on dépose une couche de cristaux liquides. La lumière est modulée (en phase ou en amplitude) par effet électro-optique. La recherche est aujourd'hui centrée autour des cristaux liquides ferroélectriques (FLC) à cause leur faible tension de commande qui conduit à des temps de commutation rapides (de l'ordre de la centaine de microsecondes, [Moigna97]). L'ensemble est recouvert d'une contre-électrode conductrice transparente et d'une couche d'alignement (*cf.* Ann.A). Le grand avantage de cette technique est de pouvoir réaliser des densités de PEs très grandes (facilement de l'ordre de 256x256 sur une pastille de 5mm²) et offrent donc la possibilité d'interconnexions optiques massives. Le temps de commutation des CLF/CI, bien que rapide par rapport à celui des cristaux liquides nématiques (qui se mesure en dizaines de *millisecondes*) reste toutefois trop lent pour implanter des sorties optiques Tb/s. On a proposé cependant des routeurs optiques basés sur cette technologie (les CLF y sont utilisés comme *défecteurs* [Moigna97] et aussi [Hiraba98] -il s'agit pour cette dernière référence de recherche *industrielle* japonaise...), ainsi que des réseaux de neurones reconfigurables [Johnso93], applications qui toutes les deux tentent d'exploiter la grande capacité d'interconnexion des CLF/CI.

-Modulateurs à effet électro-optique sur CI. La technique dite d'*Epitaxial Lift Off* (ELO) permet de séparer, à partir d'une mince couche de cristal aux propriétés optiques spécifiques (biréfringence), des éléments électro-optiques individuels [Yablon87]. Ceux-ci trouveront ensuite leur place dans des trous laissés à cet effet dans un circuit CMOS standard. L'avantage de cette technique d'*hybridation* est de pouvoir créer des matrices assez denses et de faible consommation, ainsi que de profiter de la technologie bien maîtrisée VLSI-CMOS (c'est donc une technologie directement concurrente de la technologie d'hybridation par *flip-chip-bonding* - voir ci-dessous).

-Matrices d'éléments SEED (*Self-Electro-Optic-Device*, [Miller87]). Les premières matrices de composants SEEDs utilisaient des diodes p-i-(MQW)-n en GaAs comme modulateurs contrôlés électriquement ou optiquement (appelés alors "transphaseurs" ou "transistors optiques") ou comme bistables optiques (grâce à une *paire* de diodes MQW connectés en série - *S-SEED* pour *Symmetric-SEED* [Lentin88]), le tout sans recours à aucune électronique supplémentaire. Chaque élément individuel permet de réaliser des opérations logiques simples (portes NOR et NAND), ou encore (pour la paire S-SEED) des points mémoire, ou la comparaison *analogique* de deux signaux optiques. La

possibilité de cascader ces matrices pour réaliser de traitements plus complexes est très intéressante ; cependant, la rapidité de commutation de l'élément SEED est limitée par le courant photoinduit - non amplifié électroniquement - qui charge la diode. Dans [Krish97a] il est estimé qu'il faudrait 20mW pour faire commuter un seul élément bistable (S-SEED) en 100ps, ce qui correspond à une énergie de commutation de l'ordre de 2pJ. Si l'on dispose d'une source de l'ordre du Watt pour alimenter une "modeste" matrice 32x32, alors ce temps devient d'au moins 5 μ s, sans tenir compte d'autres pertes optiques. On comprend qu'il soit indispensable d'ajouter une électronique supplémentaire pour améliorer la sensibilité du composant, surtout si l'on veut profiter de la cascabilité potentielle de telles matrices. C'est ce qui est réalisé grâce à la technologie monolithique FET-SEED - en substrat GaAs - ou par la technique *d'hybridation* de matrices de composants SEED sur circuit CMOS par *flip-chip-bonding* :

- Technologie FET-SEED (pour *field-effect-transistor/self-electro-optic-effect-device*). Il s'agit d'une technologie *monolithique* en substrat GaAs (voir fig.VII.2). Les fonctions optiques (assurés par des éléments SEED individuels ou par paires pour une détection-modulation différentielle) et les fonctions électroniques (transistors MESFET) sont réalisées sur le même substrat. Les éléments SEED fonctionnent à la fois comme détecteurs et comme modulateurs de lumière.




Fig.VII.2 : structure de la technologie FET-SEED sur GaAs.

Les circuits FET-SEED sont des composants optoélectroniques très performants qui peuvent fonctionner à des cadences de quelques GHz [Boyd94], notamment grâce à l'absence d'effet capacitif dû aux plots de connexion entre le composant SEED et le circuit VLSI - comme pour la technologie hybride CMOS/SEED. Par contre, la technologie VLSI sur GaAs n'est pas suffisamment maîtrisée aujourd'hui en ce qui concerne la densité du circuit et la consommation [D'Asar93].

- Technologie d'hybridation CMOS/SEED par flip-chip-bonding [Krish97a]. La technologie hybride CMOS/SEED combine des circuits CMOS en silicium avec des

éléments SEED en substrat GaAs par la technique dite de *flip-chip bonding*. La technique consiste à placer des plots de connexion (*bonding pads*) sur le circuit CMOS là où les éléments SEED trouveront leur place. Une fois que le substrat en GaAs contenant ces éléments est placé sur la puce en silicium par *flip-chip*, on procède à l'élimination chimique de celui-ci (on isole avant le circuit et les modulateurs par injection d'une couche d'epoxy protectrice entre les deux plans - voir fig.VII.3).




Fig.VII.3 : technologie hybride CMOS/SEED.

L'énorme intérêt de cette technique par rapport à la technologie FET-SEED est que l'on peut profiter de toute la recherche menée sur les circuits VLSI en technologie CMOS. Le seul désavantage est que la cadence de fonctionnement des éléments SEED se trouve un peu réduite, en raison des effets capacitifs des plots d'interconnexion électriques (on a démontré cependant des cadences allant jusqu'au GHz [Woodw95a]). Dans le §4.2, on décrira plus en détail les circuits CMOS de "commande" des éléments SEED. En effet, c'est l'ensemble circuit-decommande/élément-SEED qui détermine les performances finales de l'élément de transduction optoélectronique.

Notons que ces deux techniques permettent évidemment d'accroître "l'intelligence" des pixels individuels (à plus juste titre appelés *processeurs élémentaires*) qui peut s'élever à plusieurs centaines de transistors pour l'amplification, le traitement et la mise en forme du signal.

2.3.2.2 Matrices de pixels intelligents *sources* de lumière.

Il s'agit de composants utilisant des transducteurs optiques pouvant émettre de la lumière (VCSELs, LEDs et photothyristors). Les technologies d'hybridation

précédemment décrites permettent également l'intégration de transducteurs actifs dans un circuit VLSI en silicium :

- Avec la technologie ELO, les éléments de sortie peuvent aussi bien être passifs qu'actifs (LEDs, [Vendie96]).
- La technique d'hybridation par *flip-chip-bonding* de matrices en GaAs sur des circuits CMOS en silicium vient d'être extrapolée pour des VCSELs [Krishn98].

Par ailleurs, en substrat GaAs il est possible d'intégrer *monolithiquement* des détecteurs MSM (métal-semiconducteur-métal), transistors MESFET et *lasers à cavité verticale* (VCSELs) [Matsuo95]. On a aussi développé sur ce substrat des matrices de *thyristors optiques* ou *photothyristors* (fig.VII.4), élément très simple et intéressant pour la commutation tout optique [Herem91a]. La paire différentielle de photothyristors (i.e. deux photothyristors branchés en parallèle) améliore notablement la sensibilité du composant [Hara90].

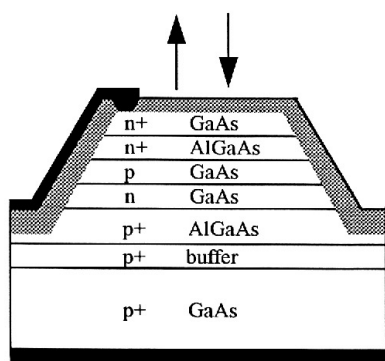


Fig.VII.4 : Structure d'un photothyristor PnpN seul. L'émission et la détection se produisent dans la même structure ; une seule fenêtre sert donc à l'entrée et à la sortie optique.

2.4 Caractérisation des circuits et systèmes optoélectroniques.

2.4.1 Introduction

Les matrices optoélectroniques sont aujourd'hui à un stade de recherche plus qu'avancé. Le domaine progresse très vite ; c'est pourquoi il semble important de disposer d'une méthodologie objective permettant rendre compte des performances d'une réalisation particulière (que ce soit d'un SPA seul ou d'une architecture optoélectronique complète comportant une ou plusieurs matrices optoélectroniques). En s'inspirant de l'analyse faite dans [Hinton94], on présentera par la suite quelques indicateurs de performance : *la connectivité optique et la densité de connexions optiques surfacique*, *la complexité*, et *la bande passante optique* d'un SPA. La comparaison de *systèmes* comportant plusieurs SPA est aussi intéressante : on définira pour ces derniers la *densité de connexion optique volumique* et la *bande passante optique système*.

Tout d'abord, quelques définitions générales ; pour un SPA, on définira :

- Un *plot de connexion optique* (ou électronique) comme étant le dispositif physique permettant de véhiculer un signal optique (ou électronique) en dehors de la

matrice (*pin-out* en anglais). Le nombre de plots optiques d'une SPA est donc une quantité indépendante du choix du codage de l'information.

- Un **port** optique (ou électronique) est le dispositif physique permettant l'échange (entrée ou sortie) d'une *unité d'information binaire* (bit). Le port peut être *différentiel* : il comporte alors 2 plots de connexion. La définition du nombre de ports d'une SPA dépend donc du type de codage. Pour éviter des confusions ultérieures, on adoptera un point de vue privilégiant le codage *interne* de la matrice (par rapport à l'utilisation des sorties faite par le *système* qui la contient). Ainsi, une matrice comportant 100 PE ayant chacun 4 connexions pour réaliser une entrée et une sortie différentielles selon le point de vue SPA, comportera 2 ports par PE et 200 ports au total.

De façon équivalente, mais pour un *système* optoélectronique comportant une ou plusieurs SPAs, on définira :

- Une **interconnexion** (ou simplement *connexion*) optique comme étant le chemin optique (*light-pipe*) reliant deux **plots** de connexion optique ; et
- Un **canal** optique comme étant le chemin optique permettant de relier deux **ports** optiques.

2.4.2 Caractérisation des matrices optoélectroniques.

Voici quelques indicateurs de performances utiles permettant de caractériser un SPA :

a) Connectivité et densité d'interconnexion optique (DIO). Le nombre de plots ou connexions optiques -entrées et sorties- est évidemment un paramètre important pour caractériser un SPA. La *densité d'interconnexion optique* est définie comme le nombre moyen de plots optiques (entrées + sorties) dont est munie la matrice par unité de surface ; ce paramètre dépend très fortement du choix et de la maturité technologique. On appellera *connectivité* de la matrice, le nombre de *ports* optiques de la matrice.

Exemple. Pour une matrice de 1 cm² comportant 1000 PEs, ayant chacun un port d'entrée et un port de sortie optique tous deux *différentiels*, la DIO serait de 4000 connexions/cm², et sa connectivité de 2000 ports/matrice. La connectivité de SPIE600 est de 576 ports(différentiels)/puce ; sa DIO est égale à $576 \times 2 / 0,26(\text{cm}^2) = 4431$ connexions/cm².

b) Complexité ou intelligence (QI). Un *Smart Pixel Array* peut être plus ou moins "intelligent". A la limite inférieure de l'échelle, on trouve les matrices de détecteurs ou d'émetteurs comme les CCD (avec toutefois un peu d'électronique), les matrices de VCSEL, les matrices de S-SEED, les SEED bistables optiques, etc. Cependant, tout l'avantage des SPA réside dans la possibilité de traiter les données au sein même de la matrice, pour renvoyer ensuite le résultat par voie optique et électronique. C'est cette

capacité qui fait la spécificité des SPAs parmi les PICs (pour *Photonic Integrated Circuits*), ces derniers étant des matrices de composants optoélectroniques intégrés monolithiquement sur le même substrat mais n'ayant aucune structure électronique de traitement du signal (lasers, détecteurs, guides optiques, réseaux, coupleurs, etc.). La complexité d'une matrice de pixels intelligents sera définie comme le nombre *moyen* de transistors par PE (rapport du nombre total de transistors au nombre total de PEs). Le QI d'un véritable SPA doit correspondre assez exactement au nombre de transistors d'un PE quelconque de la matrice - puisqu'ils sont en principe équivalents et qu'il n'existe pas beaucoup d'électronique supplémentaire d'entrée/sortie, ni d'unité de traitement importante en dehors du PE. Le QI de SPIE600 s'élève à 112 (Chap.III, §5.2).

c) Bande passante optique (BPO). L'avantage des SPA par rapport aux puces électroniques traditionnelles est de disposer de ports *optiques* en plus des ports électriques pour augmenter leur bande passante totale. Par ailleurs, pour bien exploiter les possibilités des interconnexions en espace libre, un SPA est censé avoir une bande passante optique bien plus large que sa bande passante électronique. La bande passante optique (BPO) est définie comme la somme portant sur tous les *ports* d'entrée et de sortie optiques (un *port différentiel* comprend deux *plot de connexion*) de leur bande passante optique individuelle (BPO_i). Encore une fois, pour éviter les confusions on a adopté le point de vue "interne" au SPA : il se peut par exemple qu'une autre partie du système puisse lire optiquement la valeur affichée sur le(s) port(s) de sortie du PE, tandis que celui-ci est en cycle de réception ou en train de réaliser une étape de calcul. A moins que ce fonctionnement simultané des ports ne soit prévu par le circuit électronique⁷⁶, on sera amené à considérer la bande passante individuelle *moyenne* du port d'entrée et de sortie ; ainsi, si un PE comporte 2 ports optiques (une entrée et une sortie) dont la bande passante individuelle est de 100Mb/s, mais que le circuit ne prévoit pas ce fonctionnement simultané des ports, alors la BPO_i de chacun d'eux sera seulement de 50Mb/s. Inversement, si une SPA possède 1000 ports d'entrée optique et 1000 ports de sortie optique opérant à 100 Mb/s capables de fonctionner de façon simultanée, alors la capacité de transfert optique sera de 200 Gb/s. Il s'ensuit que la BPO_i dépend aussi bien de la rapidité de la transduction optoélectronique que de la cadence de traitement électronique du PE (un exemple de calcul sera donné en détail au §5).

d) La bande passante électrique (BPE) est définie de la même façon, mais respectivement aux *ports électriques*.

e) La bande passante globale (BPG). C'est la bande passante qui résulte de la somme des deux quantités précédentes (e) et (f). La BPG peut être considéré comme un indicateur de performances globales *off-chip* de la matrice optoélectronique, mais le rapport BPO/BPE est plus intéressant pour analyser les performances du bus optique.

Exemple. La fréquence de coupure des phototransistors en montage différentiel de SPIE600 est de 250 kHz (voir Chap.III,§5.4). Sa BPO est donc égale à 576×250 kHz = 144Mb/s, puisque chaque PE (il y en a 576 fonctionnels) comporte *un* port optique d'entrée. Les registres à décalage de SPIE600 ont été testés jusqu'à 10MHz. Puisque le bus électronique de SPIE600 comporte 24 ports, la BE est égale à 24×10 MHz = 240Mb/s. On voit déjà que SPIE600 n'est qu'un prototype de SPA très médiocre, puisque $BPO < BPE$. Cependant, il suffirait de changer la taille de la matrice (toutes choses étant égales par ailleurs) pour réaliser un bon rapport BPO/BPE. En effet, la BPO augmente comme le carré de la largeur de la puce, tandis que la BPE n'est que proportionnelle à celle-ci. La taille minimale d'une matrice optoélectronique utilisant la technologie de SPIE600, et telle que $BPO \geq BPE$ est de 40×40 PEs : avec les techniques de photolithographie actuelle 0,3-0,2 μm , on pourrait aisément réaliser une matrice 100×100 sans rien changer à la taille de la matrice. La BPE serait alors d'à peu près de 100×10 MHz = 1Gb/s, contre une BPO de $100 \times 100 \times 250$ kHz = 2,5Gb/s⁷⁷).

Le tableau *tab.VII.1* ci-dessous donne un aperçu global des bandes passantes optiques individuelles relatives à plusieurs types de transducteurs optoélectroniques.

Technologie	Energie de commutation par unité de surface (fJ/ μm^2)	Bande passante (Mb/s)	Puissance dissipé / Gb.s ⁻¹ (mW/Gb.s ⁻¹)
CLF/CI	~10	0,003 (!)	---
Si seul (SPIE600)	---	0,25 (détection)	---
S-SEED	200	0,2	---
Phototyristor	0,2	50 Mb/s ; 38b/s (!)	---
FET/SEED	8	100	120
CMOS/SEED	3	600	1
LED	28	250	20
VCSEL	140	600	23

Tab.VII.1 : performances et caractéristiques des différents composants optoélectroniques. Les données sont issues principalement de [OIIC98]. Pour le CLF/CI, on a pris comme exemple le circuit de Displaytech -voir Ann.A). Pour les phototyristors PnpN, on lit dans l'ordre : performances maximales trouvés dans la littérature [Kirk97] et résultat de notre étude pour une utilisation en cascade [Chavel99]). (La troisième colonne indique la puissance dissipé par une matrice réalisant une BPO totale de 1 Gb/s).

Il ressort clairement du *tab.VII.1* que l'on peut diviser les SPAs entre *rapides* et *lentes*; plus précisément, nous poserons les définitions suivantes :

⁷⁶ c.à.d. que chaque PE doit pouvoir modifier la valeur de sa sortie en même temps qu'il réalise l'acquisition de données -on serait tenté d'utiliser le mot *pipe-line* pour le traitement du flot des données ininterrompu entre l'entrée et la sortie du PE.

⁷⁷ On peut supposer très grossièrement que le facteur d'échelle ne change pas trop les caractéristiques de photodétection : la surface *photosensible* des phototransistors étant réduite en proportion avec leur *capacité*, la fréquence de coupure n'est donc pas altérée.

- Matrices à Haute-Performance (ou HP-SPA). Les technologies les plus performantes (FET-SEED, VCSEL, CMOS/SEED, etc.) servent plutôt à réaliser des matrices rapides (au moins 100Mb/s par port) mais de faible connectivité. Elles sont utiles pour réaliser des interconnexions en espace libre entre processeurs ou cartes (parfois appelés *interconnexions intelligentes*). Dans celles-ci, la complexité de chaque PE peut être assez grande, la cadence de fonctionnement aussi.
- Matrices à Haute Densité (HD-SPA). A l'opposé, les matrices à haute connectivité sont aujourd'hui plutôt lentes et leur utilisation est donc réservée à l'acquisition, le traitement et l'affichage d'images⁷⁸, applications pour lesquelles la complexité du pixel peut être très réduite (de l'ordre de 6 transistors par pixel pour l'adressage actif à RAM statique [Johnso93]). Pour l'acquisition et le prétraitement, on voit aujourd'hui sur le marché des *caméras intelligentes* (ou *Smart Pixel Sensors*), qui sont parfois de véritables prototypes de rétines artificielles à base de CCD et plus récemment réalisées avec des photodétecteurs CMOS (grâce à la technologie APS, pour *Active Pixel Sensor* [Blanc98]). Pour l'affichage intelligent (on parle d'*écrans intelligents* ou *Smart-SLMs*), la technologie de choix est le cristal liquide ferroélectrique sur circuit intégré ou CLF/CI [Moigna97]].

Encore une fois, la particularité de notre processeur est d'être en même temps une rétine artificielle (l'image peut être rentrée directement sur la puce) et un processeur de type SPA aux interconnexions optiques. La densité de PEs améliore la *résolution* de la rétine ; la rapidité des ports optiques, la *qualité* du traitement. Il est à noter que ces paramètres sont fondamentalement *indépendants* car le processeur est parallèle. L'idéal serait donc une rétine à la fois dense (grande connectivité) et rapide (bande passante élevée). Ces paramètres sont pourtant liés technologiquement, puisque la dispersion des composants rapides au sein d'une même matrice n'est pas aujourd'hui très bien maîtrisée quand celle-ci devient trop large. Il y a donc un compromis à faire et les performances de notre prototype seront plutôt moyennes en ce qui concerne la densité d'interconnexion par rapport aux HD-SPA, et en ce qui concerne la bande passante en comparaison avec les HP-SPA.

Les figures *fig.VII.5* et *fig.VII.6* rendent compte du progrès réalisé dans le domaine des SPA ; elles rendent compte des résultats *expérimentaux, démontrés et publiés*⁷⁹. On

⁷⁸ Le besoin existe pourtant d'avoir des modulateurs de lumière très rapides (corrélateurs temps réel pour applications embarquées par exemple). Des matrices à haute densité employant des technologies rapides de type modulateurs à puits quantiques sont aujourd'hui au stade expérimental (une matrice de 128x128 GaAs-MQW attachés au circuit CMOS par des plots de contacts en Indium et opérant à 100kHz est rapporté dans [Worche96]).

⁷⁹ On trouve dans la littérature trois sortes de résultats : (1) expérimentation sur une partie de la matrice, voire sur *un seul canal* optique, fonctionnant à sa cadence maximale (source optique adapté rapide et puissante) ; (2) démonstration du fonctionnement de la matrice toute entière, ou pour le moins d'un grand nombre de ses PEs à cadence très réduite - soit parce que l'on ne dispose pas de puissance, soit parce que le matériel électronique/optique simulant l'entrée ou la sortie n'est pas capable de "suivre" ; (c) enfin, un calcul de performances théoriques. **Exemple:** *Fast optical thresholding* [Buczyn98]. Il s'agit d'une matrice

remarquera que les performances sont parfois en contradiction avec ce que l'on pourrait attendre selon la hiérarchie exposé dans le *tab.VII.1* ; ceci est dû en particulier au fait que la BPO_i des ports dépendent fortement de la puissance optique de la source-signal. Ainsi, les performances maximales théoriques peuvent être très différentes, mais on ne s'y attardera pas car d'une part elles sont difficiles à calculer (estimation de la limite de dissipation thermique, fréquence de coupure du circuit électronique parfois indisponible, etc.), et d'autre part elles ne sont pas un indicateur très parlant de l'évolution technologique réelle. Un exemple de calcul de performances théoriques complet sera donné néanmoins au §4, préparant une éventuelle réalisation expérimentale (PPOS/98). Les *fig.VII.5* et *fig.VII.6* montrent donc les performances démontrés de quelques matrices optoélectroniques en termes de bande passante optique, connectivité et complexité individuelle du PE ; on a placé SPIE600 dans ces figures à titre de comparaison, bien que ce prototype en silicium ne possède pas de *sorties* optiques.

8x8 de thyristors optiques. On a : (1) résultat sur un unique canal optique : BO_i rapporté de 50Mb/s ; (2) expérience sur 3x3 PEs, et source optique commandé par SLM : cadence 1kHz, donc $BO=3x3x1kHz$; (3) mais les performances théoriques sont estimées à : $BO=8x8x50Mb/s$. C'est une borne supérieure, mais qui ne tient pas compte de nombreux facteurs technologiques intéressants (capacité de dissipation thermique, existence ou non de sources adaptés - cascabilité de la matrice en particulier -, etc). On a retenu les résultats de type (c), car ce sont ceux qui disent le plus sur l'évolution des SPA.




Fig.VII.5 : Comparatif des performances pour quelques matrices optoélectroniques.

SPARCL/95 : [Wu99]

AT&T/91 : [McCorm93] (6-stage Switching Network)

AT&T/93 : [McCorm94] (5-stage Switching Network)

AT&T/94 : [Goosen94]

MARI95 : [Worche96]

BS/98 : [Walker98] (Bitonic Sorter)

SPIE600 : première version du Processeur Parallèle Optoélectronique Stochastique (Si-CMOS)

PPOS/98 : nouvelle version du PPOS en technologie CMOS/SEED (0,7 μ m)

2002/2007 : perspectives technologiques [OIIC99]

HERE/98 : [Buczyn99]

PREM/95 : [Prémon99]

DISP95 : voir annexe SLM.

UC/94 : [McKnig94]

NEC/96 : [Li96]

CITR/95 : [Plant95]




Fig. VII.6 : Caractéristiques du Processeur Élémentaire (PE ou SP - "Smart Pixel").

SPARCL/95 : [Wu99]

AT&T/91 : [McCorm93] (6-stage Switching Network)

AT&T/94 : [Goosen94]

BS/98 : [Walker98] (Bitonic Sorter)

SPIE600 : Processeur Optoélectronique Stochastique Si-CMOS

PPOS/98 : nouvelle version du POS en technologie CMOS/SEED.

HERE/98 : [Buczyn99]

PREM/95 : [Prémon99]

* analyse optoélectronique faite dans [Desmul99] pour une matrice 100x100 pixels, 10W de puissance électrique, 1W de puissance optique et une énergie de commutation de 0.1pJ pour chaque élément de transduction optoélectronique.

2.4.3 Caractérisation des performances système.

Pour l'analyse des performances système, il sera utile de définir les indicateurs suivants :

a) La connectivité optique - système. La *connectivité optique du système* sera définie comme le nombre total de *canaux* optiques dont est constitué le système.

b) La densité d'interconnexion optique (DIO). La *densité de d'interconnexion optique* sera définie comme le rapport entre la longueur d'interconnexion totale (produit du nombre d'interconnexions par leur longueur moyenne) sur le volume du système. Une étude théorique rapporté dans [Ozatkas90] montre que la longueur d'interconnexion maximale théorique que l'on pourrait faire tenir dans un volume de 1 cm³ est égale à environ 9000 km pour une longueur d'onde de 850 μm ($L=2\pi V/\lambda^2$). Ceci correspond à une DIO de 9000km/cm² (=900.10⁶ cm⁻²). C'est vraisemblablement une limite théorique qui est bien loin de celle des réalisations expérimentales (au moins 7 ordres de grandeur en dessous, voir *fig.VII.8*).

c) La bande passante optique système (BPOS) Pour les démonstrateurs comportant plusieurs SPA, la bande passante optique du système (BPOS) *n'est pas* définie comme la somme des BPO de chaque SPA. Il est en effet beaucoup plus parlant d'un point de vue système de définir la BPOS comme étant le produit du nombre de *canaux* (interconnexion port-port) optiques internes au système, par leur bande passant optique individuelle. Ainsi, la BPOS rend compte des caractéristiques du système pris comme un tout : tout d'abord, la capacité d'interconnexion des composants inactifs (hologrammes d'interconnexion par exemple) est prise en compte ; deuxièmement, la cadence de fonctionnement de chaque SPA dépend de la configuration du système, qui sera limitée par le dispositif le plus lent.

Exemple. Le prototype de routeur optique d'AT&T *System₅* [McCorm93], comprend 5 matrices 4x4=16 PEs. Chaque PE de la matrice comprend deux ports d'entrée et un port de sortie, tous deux différentiels (technologie FET-SEED). Ces matrices sont mises en cascade et interconnectées les unes après les autres grâce à un montage de convolution 4-f et un élément diffractif, de telle sorte que chaque canal optique provenant *d'un port* de sortie d'une matrice, alimente *deux ports* d'entrée de la matrice suivante (le DOE divise chaque faisceau en trois, mais un des faisceaux est bloqué exprès : on ne décompte que les canaux optiques *utiles*). La première matrice reçoit directement le signal d'un paquet de fibres optiques 8x4 (une fibre par port) ; un autre paquet de fibres 4x4 (une par port) récupère le signal de la dernière matrice. La bande passante optique individuelle d'un port est de 50Mb/s (pour toutes les matrices). Dans ces conditions, on a :

a) Une *connectivité* égale à **176 canaux**. C'est le nombre total de canaux optiques du système : $2_{\text{ports_entrée/PE}} \times 4_{\text{PE_actifs}} = 32$ canaux d'entrée arrivant sur la première matrice; $4_{\text{PE_actifs}} \times 1_{\text{port_sortie/PE}} \times 2_{\text{fan_out(CHG)}} \times 4_{\text{nombre SPAs-1}} = 128$ canaux reliant la première et la cinquième matrice ; $4_{\text{PE_actifs}} \times 1_{\text{port_sortie/PE}} = 16$ canaux de sortie de la dernière matrice.

b) Le nombre d'interconnexions est égal au double de la connectivité : $176 \times 2 = 352$ (deux interconnexions par *canal* : codage différentiel). La longueur moyenne d'interconnexion est égale à 25 cm. Le système occupe un volume d'environ $28 \times 35 \times 12 \text{ cm}^3$. Il s'ensuit que la *densité d'interconnexion optique* est égale à $352 \times 25 / (28 \times 35 \times 12) = 0,74 \text{ cm}^{-2}$ ($\ll 900 \cdot 10^6 \text{ cm}^{-2}$!)

c) Le fonctionnement du système n'a été démontré que pour **8 PE actifs**, d'où le placement du point correspondant dans la figure de mérites (*fig.VII.7*) : la bande passante optique n'est pas égale à $176 \times 50 \text{ Mb/s} = 8,8 \text{ Gb/s}$, mais à la moitié : **4,4 Gb/s**.

Les figures suivantes (*fig.VII.7* et *fig.VII.8*) rendent compte des performances *système* de plusieurs démonstrateurs fonctionnels réalisés à base de SPAs (routeurs optiques, processeurs optoélectroniques, etc.). Deux valeurs y sont rapportées pour le système utilisant la puce SPIE600 : (E) pour le système à base d'interconnexions électriques, et (O_{v4}), (O_{v8}) et (O_{v12}) pour le système utilisant les interconnexions optiques aux 4, 8 et 12 voisins (*cf.* Chap.V), en supposant que la boucle de rétroaction puisse fonctionner à la cadence maximale du SLM (2,5 kHz). Nous avons fait aussi une prévision des performances futures (2002 et 2007) pour la technologie CMOS-SEED [OIIC99] en considérant un système hypothétique comportant 5 SPAs 64×64 cascades (DOE d'interconnexion de 1 vers 2) - système équivalent en complexité au prototype de routeur optoélectronique pour les télécommunications d'AT&T, *System₅* [McCorm94]. Le volume du système est réduit ($3 \times 3 \times 2 \text{ cm}$ entre les étages) grâce à l'utilisation de plusieurs modules optomécaniques (*Optical Hardware Modules*) du genre décrit dans [Ayliff99]. Les points correspondant sont notés OHM-2002 et OHM-2007.

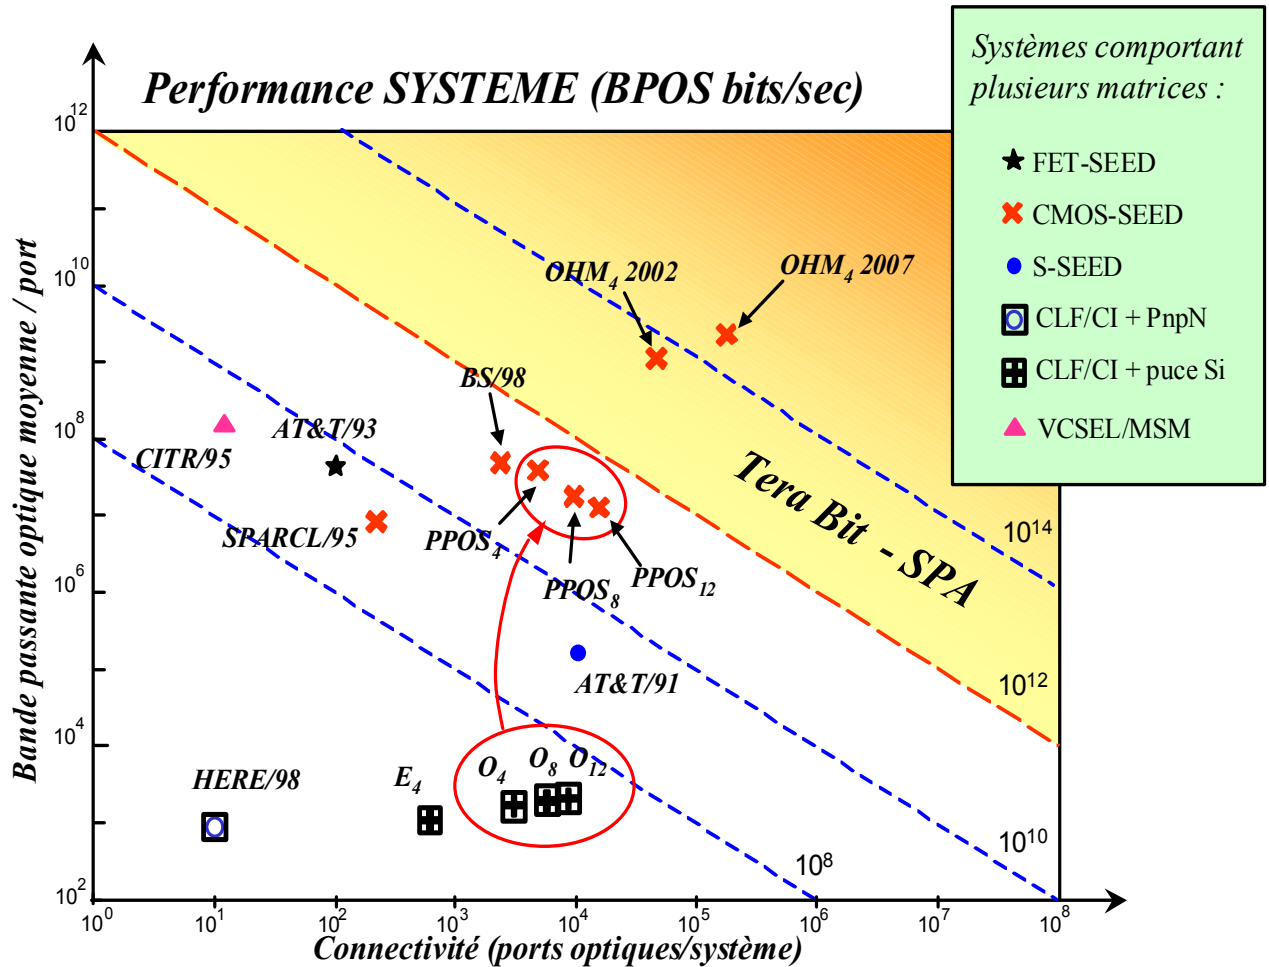


Fig.VII.7 : Performances de quelques démonstrateurs à matrices optoélectroniques :

SPARCL/95 : [Wu99]. Processeur Parallèle comprenant 3 matrices CMOS/SEED équivalentes.

AT&T/91 : [McCorm93]. 6-stage Switching Network.

AT&T/93 : [McCorm94]. 5-stage Switching Network.

OHM 2002/2007 : Perspectives technologiques CMOS/SEED [OIIC99], en utilisant un module optomécanique (Optical Hardware Module) à microlentilles [Ayliff99] ; on a pris comme exemple un système à 5 matrices et un fan-out de 1 vers 2 entre chaque étages (équivalent à AT&T System₃).

HERE/98 : [Buczyn99]. Matrice de photothyristors + SLM lent à matrice active (20Hz).

PREM/95 : [Prémon99]. Matrice de photothyristors cascadié (estimation).

CITR/95 : [Plant95]. Système (non monolithique) comprenant une matrice 4x4 de VCSELs et une matrice de détecteurs MSM (11 canaux actifs).

BS/98 : [Walker98]. Bitonic Sorter : 2 SPA différentes (ShiftRegister+ExchangeBypass).

Processeur Parallèle Optoélectronique Stochastique (PPOS) :

E₄ : Démonstrateur du PPOS pour le débruitage d'images binaires (Chap.III). Puce Si-CMOS (SPIE600)+ un SLM CLF/CI pour l'introduction de l'image à traiter (cadence max. 1250Hz); interconnexions électriques aux 4 plus proches voisins.

O_{4,8,12} : Démonstrateur pour la détection du mouvement (Chap.V) avec boucle optoélectronique non monolithique : puce Si-CMOS et deux SLM CLF/CI (introduction de l'image et rétroaction du champ de labels -cadence maximale de 2500Hz); voisinage 4, 8 et 12 réalisé par convolution optique.

PPOS_{4/8/12} : PPOS en technologie CMOS/SEED avec boucle de rétroaction monolithique. Prototype à illuminateur de tableau, 1-SPA et interconnexions holographiques - 4, 8 et 12 voisins - (cf.Chap.VII).




Fig. VII.8 : Densité d'interconnexion optique volumique (DIO) pour divers démonstrateurs à base de matrices optoélectroniques bidimensionnelles (références sur la légende de la figure précédente).

La limite théorique ($L/V=2\pi/\lambda^2$, [Ozakt90]) est calculée ici pour la longueur d'onde de 850 nm, désormais -depuis 1995- standard pour les communications courte distance sur fibre optique (dans le court terme, ce standard se déplacera vers le micron et au delà [OIIC999]).

Sept ordres de grandeurs (au moins) séparent la densité d'interconnexion théorique maximale de celle des meilleures réalisations expérimentales. Il y a vraisemblablement beaucoup à faire dans le domaine des interconnexions optiques en espace libre (ce n'est plus le cas en électronique VLSI : la taille des pistes métalliques est aujourd'hui ($0,25\mu\text{m}$) à moins d'un ordre de grandeur en dessus de la limite théorique pour cette technologie - effet tunnel à $0,03\mu\text{m}$ [Mead94]).

2.5 Conclusion

Nous avons énoncé en introduction les motivations qui nous poussaient à entreprendre l'étude d'une nouvelle rétine artificielle à interconnexions optiques ; nous avons dit qu'une telle solution permettrait d'augmenter la capacité de calcul de plusieurs ordres de grandeur. Il en ressort maintenant de façon plus claire quelles devraient être les performances maximales auxquelles on doit s'attendre d'une nouvelle puce optoélectronique à entrées et sorties optiques en technologie hybride III-V (CMOS-SEED, FET-SEED ou VCSEL/MSM) : des bandes passantes *dépassant la centaine de GHz*, mais pour des tailles qui restent toutefois relativement modestes en raison de l'immaturité technologique (1997: 32x32 pixels, prévision 2002: 64x64 et 2007: 128x128 [OIIC99]). Les matrices VLSI/FLC permettraient une densité de pixels bien plus grande, mais il n'y aurait pas de gain substantiel en capacité de calcul par rapport à notre démonstrateur précédent, à base lui aussi de cristaux liquides ferroélectriques⁸⁰.

Le but du paragraphe suivant sera d'établir plus précisément les performances d'un nouveau prototype de système utilisant une puce à entrées et sorties optiques beaucoup plus performante que SPIE600.

⁸⁰ Un gain d'au plus un facteur deux : on a vu au Chap.VI,§3.2 que le temps de traitement électronique pour réaliser la rétroaction des données sur le prototype du Chap.V (lecture données sur la puce, conversion au format SLM) peut être rendu de l'ordre du temps de rafraîchissement du modulateur de lumière -pour un ordinateur cadencé à 500-600MHz. Supprimer ce temps de calcul rendrait donc le traitement à peine deux fois plus rapide par rapport au prototype non monolithique (les points O_{4/12/8} dans les figures *fig.VII.7* et *8* correspondent à cette hypothèse).

3. PPOS à entrées et sorties optiques : cahier de charges

Nous allons décrire par la suite le cahier de charges du nouveau PPOS à entrées et sorties optiques que nous proposons comme extension possible à cette thèse. La nouvelle puce n'est qu'une extension de SPIE600 en ce qui concerne le voisinage d'interconnexion (qui sera désormais traité optiquement), mais le champ à relaxer reste toujours binaire. Aucun choix technologique particulier n'est encore assumé dans cette partie.

3.1 Fonctionnalités de la puce.

La nouvelle puce est conçue pour l'implantation de l'algorithme de détection du mouvement exposé au Chap.IV. Remarquons toutefois que l'algorithme de Dumontier (voir Chap.IV,§5.5) pourrait être traité par une puce de complexité à peu près équivalente, la principale difficulté étant l'implantation de la fonction de potentiel Ψ_D , mais il suffirait d'intégrer au sein de chaque PE une table de conversion pour implémenter les potentiels non quadratiques par exemple.

Tout d'abord, la nouvelle puce *ressemble* à SPIE600 sur plusieurs points :

- 👉 Chaque cellule doit stocker une variable binaire - i.e. le champ d'étiquettes $e(s,t)$.
- 👉 Les opérations élémentaires réalisées par la cellule sont en tout point équivalentes à celles effectuées par les PEs de la puce SPIE600, à savoir : (1) calcul d'une *force locale* (somme des spins des voisins + terme de rappel) ; (2) comparaison de cette force avec un "nombre" aléatoire provenant du générateur de speckle ; le résultat permettra de (3) mettre à jour le spin. La mise à jour est contrôlée par une *horloge de couleur* (le voisinage d'ordre 1 de SPIE600 nécessitait de deux horloges - blanche et noire respectivement).

Les ressemblances s'arrêtent là, car à la différence de SPIE600, la nouvelle puce doit comprendre *aussi* :

- 👉 Une paire d'entrées optiques mais également une paire de *sorties* optiques par PE (codage différentiel en double voie). Le contenu de chaque point mémoire doit être accessible aux PEs voisins grâce à des interconnexions optiques (l'ensemble conformant le *terme de régularisation spatiale* de la force locale - cf. Chap.V, §1.1).
- 👉 La contrainte aux données peut toujours être de nature optique comme dans le démonstrateur du Chap.IV ; cependant il serait plus pratique de disposer d'une mémoire (point mémoire supplémentaire par pixel) permettant de stocker le *terme de rappel* (champ binaire d'observation $o(t)$ dans le cas du débruitage d'images, et champ binaire $b(s,t)=(2\hat{o}(s,t)-1).(2.e(s,t-1)-1)$ dans le cas de la détection du mouvement – cf. Chap.V, §1.1). Ceci pour deux raisons : (a) le terme de rappel n'est pas nécessairement une image provenant d'un système d'acquisition classique (i.e., ce n'est pas une *image*

à proprement parler), et même dans cette éventualité (débruitage d'images binaires par exemple), l'image *doit être codée au préalable de façon différentielle* sur les photodétecteurs. Un prétraitement (relativement simple) est donc indispensable ; (b) par ailleurs, le terme de rappel reste constant tout au long du recuit. Le champ d'observation ne change qu'à cadence vidéo : autrement dit, on n'a pas besoin d'une large bande passante et l'introduction de "l'image" à traiter peut se faire en utilisant le bus électronique (le temps de traitement est supérieur au temps de chargement d'une mémoire cache -voir commentaire sur les architectures SIMD, Chap.III, §1.3). Un montage optique supplémentaire pour utiliser le bus optique n'est donc pas nécessairement justifié. Dans ce sens, notre SPA s'éloigne du concept rétinien (*acquisition* et traitement), pour représenter seulement une étape plus en aval de traitement. Une version compacte d'un système de traitement d'images bas niveau assez général comprendrait par exemple une caméra intelligente chargée du prétraitement (calcul du champ d'observation et terme de rappel) et une deuxième puce responsable de la régularisation bayésienne par optimisation stochastique (voir fig.VII.9). Notre travail porte bien sûr sur cette deuxième puce, qui, comme on l'a montré précédemment, gagne beaucoup à être un SPA à entrées et sorties.




Fig.VII.9 : Le PPOS prend en charge le module de traitement (régularisation) dans un système de traitement d'images. Dans le cas de la détection du mouvement, le prétraitement consiste en une détection de changements temporels ($o(t)=CCT$) suivi d'un simple produit booléen entre le champ d'observation binaire $\hat{o}(t)$ et le champ d'étiquettes précédent $MB(t-1)$ - voir schéma algorithmique à la fin du §6, Chap.IV.

☞ C'est pour pouvoir accéder à des voisinages plus larges et reconfigurables que l'on avait introduit la convolution optique (dans une boucle de rétroaction optoélectronique *non* monolithique) dans le montage du Chap.V. On étudie maintenant les SPAs à sorties optiques comme une solution pouvant améliorer les performances de cette rétroaction qui s'est avérée trop lente ; retenons donc que le voisinage dans le nouveau système *doit* pouvoir *au moins d'ordre 2* - autrement SPIE600 ferait parfaitement l'affaire. Or, plus le voisinage est large, et plus nombreux doivent être les signaux de *couleur*⁸¹ ; pour ne pas avoir à réaliser un câblage difficile (la distribution de plusieurs horloges est encombrante et pose des problèmes délicats de retard entre les différentes lignes, sans parler de l'impossibilité de reconfigurer la couleur de façon arbitraire), on propose de garder *une seule* horloge et de rajouter deux ou trois points mémoire supplémentaires par PE, plus un compteur. La mémoire sert à programmer la couleur locale (5 couleurs sont suffisants pour réaliser un voisinage d'ordre 3, c'est à dire 12 voisins). Le PE exécutera la mise à jour de son spin seulement quand le nombre de cycles d'horloge *modulo* le numéro de couleur vaut zéro. Ceci permet de programmer plus aisément les couleurs lorsque l'on change de motif de voisinage.

☞ La programmation de la couleur implique un bus électrique additionnel. Un bus bidirectionnel (par ailleurs très utile pour le test de la matrice) pourrait être réalisé à partir de registres à décalage comme c'est le cas dans SPIE600. D'ailleurs, la complexité serait pratiquement la même que dans SPIE600 : les deux points mémoire codant les *interactions* (J_S et J_E , voir Chap.III,§5.1) sont remplacés par deux ou trois bits codant la couleur.

Une autre solution intéressante mais que l'on ne retiendra pas ici serait de programmer le coloriage *optiquement*. On garderait seulement un signal d'horloge ainsi qu'un unique signal de contrôle, tous deux communs à l'ensemble des PEs. Le signal de contrôle mettrait tous les PE dans un état de *programmation de couleur* consistant pour chaque PE à (1) mettre son compteur à 0 ; (2) compter au rythme des impulsions d'horloge ; (3) s'arrêter à la couleur courante dès réception d'un signal lumineux. Une solution pour un problème analogue a été étudiée dans [Seyd91]. En allant encore plus loin, on pourrait imaginer de fournir le signal de mise à jour de couleur de façon purement optique (il n'y aurait donc plus d'horloge électronique). Cette dernière solution permettrait de maîtriser à volonté le degré de parallélisme du processeur et d'explorer ainsi de façon contrôlée le domaine des architectures *asynchrones* [Azenco92].

⁸¹ Il s'agit là d'une nécessité découlant de considérations théoriques (*cf.* Chap.II,§2.2.7). Cependant, on a réalisé quelques simulations (restauration d'images binaires) pour un voisinage d'ordre 2 (8 voisins) et pour un coloriage qui *reste* binaire : les résultats ne peuvent pas être départagés à l'œil.

3.2 Performances attendues et choix de la technologie

Etant donné qu'une bonne qualité de traitement par recuit simulé peut nécessiter de plusieurs milliers de mises à jour (*cf.* Chap.II,§2.3.3), et si on veut réaliser des traitements au moins à cadence vidéo, alors chaque mise à jour doit se faire en moins d'une dizaine de micro-secondes. Ce qui fait des cadences de mise à jour de l'ordre de la centaine de kHz.

Le nouveau prototype doit donc disposer de composants optoélectroniques capables de réaliser une bande passante optique individuelle (BPO_i) dépassant la centaine de kHz tant à l'émission comme à la réception. La technologie CLF/CI et les matrices de composants SEED *sans* électronique d'amplification sont donc exclues (voir *tab.VII.1*). Entre la rapidité de commutation des circuits CLF/CI et les SEED dépourvus d'étage d'amplification, et celle des dispositifs hybrides CMOS/SEED ou FET/SEED, il y a en effet un rapport de plusieurs ordres de grandeur (voir *tab.VII.2*).

Technologie	Recuits sérieux à la seconde (environ 4000 mises à jour)
Photothyristor	$\approx 0,01$
CLF/CI (détection Si)	0,6
S-SEED(MQW)	5
FET/SEED (MQW)	25.000
LED(MQW)/MSM	62.500
CMOS/SEED (MQW)	150.000
VCSEL(MQW)/MSM	150.000

Tab.VII.2 : nombre de recuits sérieux à la seconde pour chaque type de composant (un recuit sérieux représente 1000 itérations, soit 4000 opérations de mise à jour pour un coloriage 4). Il existe un vide technologique dans la région de la cadence vidéo (on passe directement de 5 à 25000 recuits/s).

Il ne nous est pas paru absurde d'étudier la réalisation du processeur dans une technologie innovante, quoique *trop* performante en rapidité pour notre application. En effet, pour des images réalistes (256x256), une bande passante d'une centaine de kHz par pixel implique seulement une bande passante totale de l'ordre de 6 Gb/s. Cette quantité est à mettre en relation avec le Tbit/s, objectif des HP-SPA. Remarquons toutefois qu'avec une telle bande passante on pourrait réaliser des recuits sérieux à cadence vidéo sur des images de plus de 3000 pixels de côté (les images haute résolution - satellitaires par exemple - peuvent atteindre facilement cette résolution). On voit donc que notre étude n'est pas inintéressante, à condition de trouver un moyen de décomposer l'image en

blocs⁸² pour réaliser le recuit (multirésolution peut être?) sur une matrice de faible résolution. Par ailleurs, l'étude de démonstrateurs utilisant des HD-SPA en technologie hybride CMOS/SEED, FET/SEED ou PnpN est en soi un problème intéressant et à l'ordre du jour.

3.2.1 La paire différentielle de photothyristors.

La paire différentielle de photothyristors possède les mêmes fonctionnalités que le composant S-SEED, mais peut générer par lui même le signal optique de sortie (composant actif). La paire de photothyristors possède "l'intelligence" minimale permettant d'implanter une version simple du PPOS car elle réagit essentiellement comme un comparateur. Lorsque la tension d'alimentation de la paire est nulle, les fenêtres optiques de chacun des photothyristors sont prêts à recevoir le signal lumineux d'entrée (mode double-voie). Ensuite, la tension d'alimentation est brusquement appliquée et le photothyristor qui a reçu la plus grande énergie lumineuse possède alors la plus grande précharge et *commute en premier* : il draine ainsi tout le courant disponible et empêche la commutation de l'autre photothyristor qui reste dans l'état bloqué (comportement de type *winner-take-all*). Seul le photothyristor en état de conduction émet de la lumière : la paire différentielle possède donc deux sorties optiques complémentaires, résultat de la comparaison des signaux optiques incidents (pour plus de détails voir [Prémon99]). La juxtaposition de plusieurs matrices de photothyristors en "cascade" permet alors de réaliser des fonctions logiques plus complexes [Herem91b] et cela sans avoir recours à des sources optiques extérieures. Des cadences allant jusqu'à 50 MHz et restituant correctement le signal optique ont été rapportées [Knupfe95].

Pour nous, l'intérêt des photothyristors est la possibilité de réaliser une *convolution optique monolithique* sans avoir recours à une source de lumière externe. C'est pourquoi une étude fut entreprise dans notre laboratoire [Prémon99]. Le but final était l'intégration d'une matrice de photothyristors dans un montage de convolution par tableau de microlentilles (*LAHC* pour *Lenslet Array Holographic Convolver* [Glaser95]). Le travail concernant le module optomécanique fut mené par l'équipe de I.Glaser et A.A.Friesem à l'Institut Weizmann, en Israël. Une matrice comprenant 32 photothyristors fut mise gratuitement à notre disposition par l'équipe de M.Kuijk et P.Heremans de l'IMEC à Leuven, en Belgique. Voici les caractéristiques des phototransistors PnpN étudiés dans notre laboratoire [Chavel99] :

Caractéristiques en réception : (*photodiode*).

- Fenêtre de détection : 30x40 μm
- Sensibilité (définie comme l'énergie minimale permettant de réaliser correctement la commutation entre les deux états bistables) : bien que des sensibilités allant

⁸² C'est la stratégie utilisée par le démonstrateur SPARCL de l'University of Southern California dédié au traitement d'images par BIA (composé de 5 HP-SPA et comprenant chacune seulement 50 pixels) [Wu99].

jusqu'à 2,6 fJ à 720 nm aient été signalées dans la littérature [Kuijk95], les mesures sur notre matrice conduisent à des énergies de l'ordre de 1,2 pJ (à 783 nm).

Caractéristiques en émission : (émission de type LED).

- Fenêtre : 15x20 μm
- Divergence : Source Lambertienne (type LED).
- Puissance : 31nW par site à la longueur d'onde de 860 nm.

Il ressort de nos mesures que la puissance émise par un photothyristor en mode LED (31nW) permettrait de faire commuter à son tour une *autre* paire en un quart de milliseconde ($31\text{nW}/1,2\text{pJ} = 0,26 \text{ ms}$). Ce temps devient environ six fois plus long dans le cas d'une interconnexion holographique aux 4 plus proches voisins entre matrices cascades (l'efficacité théorique du réseau de Dammann étudié est, dans l'ordre utile, d'environ 16%, - voir Ann.B) et 10 fois plus grand pour une interconnexion aux 8 voisins (efficacité théorique d'environ 9%). Dans ce dernier cas, la durée d'un seul recuits sérieux (4000 mises à jour pour un coloriage quaternaire) est d'environ 14 secondes!. On est loin de la cadence vidéo. Par ailleurs, selon [Prémon99], le fait que le pic de sensibilité se trouve aux alentours de 720 nm, tandis que la longueur d'onde nominale d'émission est de 860 nm, pose un problème grave : en fait, à cette longueur d'onde la sensibilité chute d'un facteur 100. Des mesures plus récentes sur notre matrice montrent que seuls certains sites présentent cette chute brutale de la sensibilité. C'est en soi un résultat qui souligne l'immaturité de la technologie des PnpN (grande dispersion des caractéristiques des composants sur un même substrat), du moins sur l'échantillon déjà ancien (1995) dont nous disposons.

Conclusion La paire différentielle de photothyristors semble au premier abord le composant idéal pour implanter les fonctionnalités très simples de notre PE (voir §4.3). Cependant, ce dispositif souffre de trois handicaps majeurs :

- dispersion des caractéristiques (*mismatch*) des paires au sein de la matrice (dans notre matrice comportant 32 éléments, 4 photothyristors étaient inutilisables) ;
- faible sensibilité et faible puissance émise, conduisant à une cadence de rétroaction optique très modeste (quelques $1/0,26\text{ms}=4\text{kHz}$, bien loin des $4000 \times 25 = 100\text{kHz}$ nécessaires pour un recuit sérieux à cadence vidéo, et cela sans tenir compte du reste des pertes optiques inévitables) ;
- il s'agit de sources *lambertiennes* (ce sont des LEDs). Les inconvénients ne sont pas négligeables - diaphonie et pertes d'insertion dans les systèmes optiques - et imposent l'emploi d'un système d'imagerie adapté pour concentrer et diriger l'énergie (tableau de microlentilles par exemple [Andrew97]).

3.2.2 MQW et technologie hybride CMOS-SEED.

La technologie hybride CMOS-SEED a été développée dans l'esprit de ne pas rentrer en concurrence avec les circuits en silicium, mais plutôt de tirer profit de leur maturité

technologique et leur évolution constante [Hinton97]. De plus, la technologie de *flip-chip-bonding* (cf. §2.3.1) permet de libérer de la place pour la logique électronique du PE. On s'intéressera ici à l'hybridation de *modulateurs à multiple puits quantiques* ou MQW (pour *multiple quantum wells*) en GaAs sur des circuits silicium.

Principe de fonctionnement des modulateurs. Les *modulateurs* à électro-absorption sont basés sur la modification de l'absorption résultante de l'application d'un champ électrique. Un mécanisme particulier d'électro-absorption, connu sous le nom d'effet *Stark confiné quantiquement* rend la modulation beaucoup plus importante au sein des structures à multiples puits quantiques.

Rappel. Dans les semi-conducteurs massifs et en absence de champ électrique extérieur, le coefficient d'absorption est *nul* si l'énergie de l'onde lumineuse est inférieure au *gap* entre la bande de valence et la bande de conduction ; au dessus du *gap*, l'absorption grandit de façon *continue* et parabolique avec l'énergie de l'onde. L'application d'un champ électrique déplace le spectre d'absorption vers les grandes énergies : c'est l'effet *Franz-Keldysh* ou d'*électro-absorption*. La modulation optique (en phase et en amplitude) est donc possible sur n'importe quel semi-conducteur, pour peu que l'énergie lumineuse corresponde à la largeur de leur bande interdite. L'effet peut être fortement amplifié en utilisant des matériaux à puits quantiques multiples, structures périodiques possédant alternativement des largeurs de bande interdite différentes, fabriqués sur le substrat semi-conducteur (par épitaxie par exemple). Les bandes d'énergie se divisent alors en niveaux discrets et le coefficient d'absorption présente alors des marches en escalier. Il s'ensuit que, pour une longueur d'onde donnée, la variation de l'absorption par application d'un champ électrique devient plus abrupte. Mais la contribution la plus importante à cette variation provient d'un effet qui n'est notable que dans les structures à MQW : l'absorption *excitonique* (i.e., l'absorption produite par création de paires électron-trou ou *excitons*). Dans ce genre de structures, le confinement de la fonction d'onde de l'exciton augmente son énergie de liaison et donc sa durée de vie ; on observe alors - et cela même à température ambiante - un *pic* de résonance dans le spectre d'absorption pour une énergie correspondante à l'énergie de l'exciton. Le déplacement du bord de la bande d'absorption mais surtout celle *du pic excitonique* produisent une transition entre état "passant" et "bloquant" beaucoup plus abrupte : c'est l'effet *Stark confiné quantiquement*.

Le dispositif de la *fig.VII.2* est réalisé en GaAs et AlGaAs. La lumière modulée est perpendiculaire au plan des couches. On obtient la meilleure modulation pour la longueur d'onde de 850 nm. A cette longueur d'onde les contacts dopés n et p-AlGaAs sont transparents ; par contre, le substrat en GaAs ne l'est pas, et il doit être enlevé. Ces modulateurs peuvent être utilisés en transmission, et le contraste entre l'état passant et bloquant est alors de l'ordre de 2:1 pour des excursions en tension de moins de 10V. Le composant peut également être utilisé en réflexion : il suffit pour cela de rajouter une structure réfléchissante (typiquement une structure multicouches produite également sur le substrat). Enfin, si l'épaisseur de cavité est bien maîtrisée, le contraste peut être rendu - en principe - infini en rajoutant une deuxième structure réfléchissante (cavité Fabry-Perot).

La région des puits quantiques - qui est intrinsèque - est généralement entourée d'une région dopée p et une région dopée n : on obtient ainsi une diode $p-i(MQW)-n$ et la tension électrique appliquée se retrouve presque intégralement aux bornes de la zone active intrinsèque (non dopée). C'est pourquoi la structure peut fonctionner également en *détection*, comme une photodiode. Comme expliqué au §2.3.1, les performances en détection peuvent être fortement améliorées grâce à l'adjonction d'un étage d'amplification électronique. En technologie hybride CMOS-SEED, ces étages sont réalisés sur le circuit Si-CMOS sur lequel est déposée la structure en GaAs. Les caractéristiques finales du transducteur optique dépendent de l'ensemble modulateur(MQW)/circuit-électronique. On s'est bien évidemment intéressé aux éléments de détection *différentielle*. Plusieurs résultats ont été publiés dans la littérature ; on retiendra ici les ordres de grandeur suivantes :

En détection :

- La sensibilité S (*responsivity* en anglais) des modulateurs à MQW est supérieure à 0,5 A/W [Woodwa94]. La *différence* d'énergie minimale ΔE_{min} détectable permettant de coder une information binaire (ou sensibilité du récepteur du PE) dépend de S mais aussi de l'étage de d'amplification électronique (et en général elle dépend également de la *cadence* d'acquisition). Un grand nombre de circuits plus ou moins standards ont été proposés pour l'étage de amplification dans les circuits transducteurs optiques (voir par exemple [Alexan97]) ; quelques réalisations testées et publiées comprennent l'amplificateur à gain en tension ou DCR (pour *diode-clamped receiver*, car deux diodes sont utilisées pour limiter l'excursion en tension à l'entrée du préamplificateur, voir §4.2) [Lentin94], le TIA (pour *transimpédance amplifier*, qui est un amplificateur non-intégrateur à boucle de rétroaction) [Woodw96a] et le CSA (pour *charge sense amplifier*, dérivé des détecteurs différentiels ultrasensibles employés pour faire commuter des cellules élémentaires dans les mémoires RAM) [Dines96]. Pour une cadence légèrement supérieure à 620 Mb/s, [Woodw96b] reporte des sensibilités⁸³ de l'ordre de 60 fJ pour le DCR, 30 fJ pour le TIA et 60 fJ pour le CSA. Malgré un circuit électronique un peu plus élaboré (47x29 μm^2 contre 25x29 μm^2 pour le DCR en techno 0.6 μm [Forbes98]), l'amplificateur à transimpédance est souvent préféré aux récepteurs-intégrateurs comme le DCR, car il présente à la fois plus de dynamique, une plus large bande passante (assuré par une rétroaction passive ou active du signal - ce qui permet de préserver une sensibilité élevée [Willia86]) et surtout est moins sensible aux dispersions des caractéristiques électriques (en particulier la capacité d'entrée de l'amplificateur, cf. §4.2).
- La taille de la fenêtre optique est de l'ordre de 100 μm^2 .

⁸³ la sensibilité est définie plus précisément dans cette étude, comme étant l'énergie minimale permettant de réaliser un BER (*bit error rate*) supérieur à 10^{-9} pour une séquence pseudo-aléatoire de $2^{23}-1$ bits.

- Le pic de sensibilité en fonction de la longueur d'onde est déterminé par la structure de la cavité à MQW. La compagnie américaine Lucent Technologies [Krish97a] développe des modulateurs en AlGaAs fonctionnant à la longueur d'onde de 850 nm ; par contre, les modulateurs à puits quantiques en InGaAs testés à l'Université de Heriot-Watt [Walker98] fonctionnent à 1047nm : à cette longueur d'onde, le substrat en GaAs est *transparent*, ce qui permet d'éviter l'étape d'élimination du substrat (*cf.* §2.3.1).

En "émission" :

- Il s'agit de *modulateurs* de lumière en réflexion. La source optique est externe, ce qui a malgré tout quelques avantages : on peut contrôler facilement la puissance optique *globale* disponible, ainsi que la synchronisation des durées de détection entre différents PEs. La réflectivité à l'état passant est de l'ordre de 50-70%.
- Le contraste est maximal pour la longueur d'onde de réception (il est donc immédiatement possible de cascader plusieurs matrices ou de réaliser une rétroaction monolithique). Le contraste pour des excursions de tension de 5 V est de l'ordre de 2:1 (entre 1,5 et 2). Il existe des solutions qui permettent d'améliorer ce contraste (par empilement de modulateurs et/ou en créant une cavité Fabry-Perot) ; mais pour notre démonstrateur, le fait que le contraste soit faible n'a pas grande importance puisque la détection est différentielle.
- Le modulateur est assez sensible aux variations thermiques (décalage du pic de résonance de l'ordre de 0.3nm/C°), mais il semble que la conductivité thermique du composant hybride entier soit suffisante pour que l'on puisse stabiliser la température de façon classique (*heat-sink*) [Krish97a].
- La possibilité d'utiliser ces modulateurs par réflexion et en lumière collimatée est un avantage certain par rapport aux photothyristors : on évite ainsi le tableau de microlentilles pour collecter la lumière.

Uniformité Les modulateurs sont des composants relativement simples et bien maîtrisés. La dispersion des caractéristiques (*mismatch*) est moindre que pour les matrices de photothyristors. Le rendement de fabrication (*device yield*) est également très bon (de l'ordre de 99.9% pour des matrices 64x68 [Ashok97]).

3.3 Conclusion

Les composants CMOS-SEED présentent donc un grand nombre d'avantages par rapport aux composants PnpN, avantages qui l'emportent sur l'inconvénient lié à la nécessité d'une source externe de lumière. Remarquons aussi la très bonne perspective d'évolution pour la technologie hybride CMOS-SEED : des expériences récentes permettent de supposer que d'ici peu on pourra disposer de puces contenant plus de 47000 éléments SEED (216x108 entrées ou sorties différentielles par matrice!) sur une surface de 3,7x3,7mm², fonctionnant à plus de 2,48 Gb/s avec seulement 300 μW de

puissance optique incidente pour la commutation en mode différentiel [Woodwa97]. Si l'on peut faire fonctionner tous les éléments SEED en même temps, la bande passante optique résultante est de 60Tb/s (pour une source optique de 7W). Nous avons retenu cette très prometteuse technologie hybride CMOS/SEED pour le nouveau prototype.

4. Le PPOS en technologie hybride CMOS-SEED.

Nous allons esquisser maintenant la structure d'un SPA en technologie hybride CMOS-SEED, ayant les fonctionnalités du processeur parallèle optoélectronique stochastique pour le recuit simulé.

4.1 Les dispositifs SEED d'entrée/sortie.

Commençons par une remarque générale : la détection différentielle, nécessaire pour implanter le générateur de nombres aléatoire optique (Chap.III,§5.3), est robuste vis-à-vis du faible contraste des modulateurs à MQW (de l'ordre de 2) et de leur éventuelle dispersion spatiale. En effet, dans le cas d'une détection mono-voie, il faudrait toujours soustraire une quantité constante à la force (offset), avant de comparer celle-ci au photocourant induit par le speckle. Or, le contraste non infini des modulateurs introduirait un biais qu'il faudrait corriger localement pour obtenir des valeurs correctement centrés. La détection différentielle de la force optique de régularisation opère de la même façon avantageuse que pour la détection différentielle de speckle, en limitant le problème lié à la dispersion des caractéristiques et en centrant automatiquement la valeur de la force optique. Nous avons envisagé deux possibilités pour l'entrée et la sortie du PE :

- Les dispositifs SEED d'entrée et de sortie sont physiquement *distincts*.
- L'entrée et la sortie se font par le *même* dispositif SEED *bidirectionnel*. Cette dernière solution présente de nombreux avantages. D'une part on gagne en densité de PE sur la puce. D'autre part, c'est une solution bien adaptée à notre démonstrateur puisque le coloriage des PE implique qu'un même PE ne fonctionne jamais en mode réception et émission *simultanément*. Enfin, d'un point de vue technologique, il y a moins de paramètres à contrôler.

La deuxième solution est a priori la plus intéressante ; cependant, les cellules CMOS précaractérisées dont nous disposons pour commander les modulateurs ne permettent pas de réaliser ces deux fonctions simultanément. Nous avons donc opté de pourvoir chaque PE de 4 structures à MQW : deux éléments pour réaliser l'entrée différentielle, et 2 pour la sortie (voir *fig.VII.10*).




Fig.VII.10 : Fenêtres optiques de détection et de modulation dans le dispositif CMOS-SEED étudié. Chaque PE dispose de 4 plots de connexion optiques (2 plots de sortie et 2 plots d'entrée), pour former 2 ports optiques différentiels (entrée et sortie).

4.2 Les circuits de commande des modulateurs.

Nous allons considérer uniquement le détecteur différentiel à gain en tension (ou DCR), dont les principaux avantages sont la simplicité et la compacité. Le circuit en question est schématisé dans la fig.VII.11. La tab.VII.3 donne la valeur caractéristique de divers paramètres du circuit, pour la technologie CMOS-SEED. Nous allons reprendre le principe de fonctionnement au §5.3.2 (étude du bilan optoélectronique du système), mais une description plus approfondie peut être trouvée dans [Lentin94].

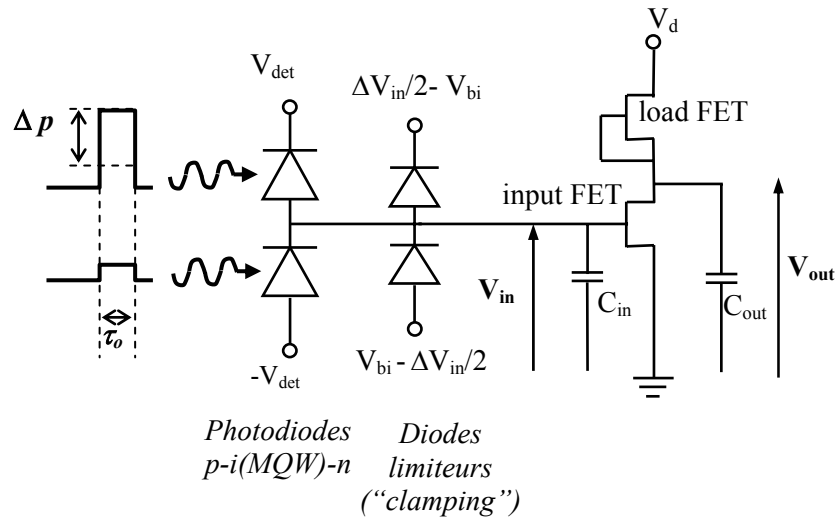


Fig.VII.11 : Schéma électrique du détecteur différentiel intégrateur (de type DCR). La seconde paire de diodes limite l'excursion en tension V_{in} et maintient la polarisation inverse des photodiodes (d'après [Lentin94]).

Définition	Symbole	Valeur typique
Sensibilité moyenne des MQW.	S	$0.5 A/W (*)$
Capacité du détecteur à MQW	C_{cap}	$200 aF/\mu m^2$
Tension commande modulateur (état passant/bloquant)	V_o	$8V$
Surface de la fenêtre de détection/modulation.	A	<i>environ</i> $100\mu m^2$
Tension de commutation à l'entrée de l'amplificateur	ΔV_{in}	$0.25 V$
Tension de commutation logique de sortie	ΔV_{log}	$1 V$
Transconductance FET	g_m	$10^{-3} S$
Capacité de grille du transistor	C_{input}	$60 fF$
Capacité des plots (flip-chip)	C_{pad}	$200 fF$
Capacité sortie étage amplification	C_{out}	$120 fF$

Tab.VII.3 : caractéristiques du circuit récepteur DCR, en technologie CMOS-SEED de la fig.VII.11. (*) G.Clarici et M.Desmulliez de l'université de Heriot-Watt ont reporté récemment une sensibilité S maximale de $0,86 A/W$.

4.3 Architecture électronique du processeur élémentaire (PE).

Le schéma de la fig.VII.12 ci-dessous et les explications données au §3 sont suffisantes pour comprendre le fonctionnement électronique du processeur élémentaire. Chaque PE n'est pratiquement autre chose qu'un *répétiteur* formé par un *détecteur différentiel* et un *émetteur* (*differential transceiver*, ou *two-beams transceiver* [Woodw96b]). En effet, si l'on met de côté le mécanisme de coloriage, alors chaque PE se comporte comme un répétiteur dont le seuil de détection différentiel serait contrôlé par le terme de rappel⁸⁴. La littérature abonde aujourd'hui sur ce sujet (entre autres, motivé par la recherche sur les *routeurs* optiques en télécommunications).




Fig.VII.12 : Schéma d'un processeur élémentaire (PE). Il comprend un détecteur différentiel, un émetteur, et 5 points mémoire binaires : trois bits (a,b et c) pour le codage de la couleur ; un bit (e_i^t) pour le champ en calcul ; enfin, un bit (b_i^t) pour le terme de rappel (binaire dans les exemples étudiées).

Remarque : l'implantation de l'algorithme de Dumontier (ou de Lalande) implique la manipulation de quantités continues (le champ d'observation continu $o(t)=DI(t)$ à niveaux de gris est directement pris en compte dans le calcul de la force locale, voir Chap.IV, §5.4 et §5.5). A moins de disposer d'un nombre de bits par PE plus ou moins conséquent permettant de stocker ces quantités, l'introduction par des moyens optiques de la différence inter-image (DI) non seuillé est la seule solution

⁸⁴ Et si le terme de rappel est introduit de façon optique, alors un PE est *exactement* un comparateur avec mémoire binaire (=bistabilité). C'est pourquoi on s'était intéressé dans un premier abord aux photoristors.

envisageable. Encore faudrait-il, pour préserver l'avantage de la détection différentielle, coder cette image en mode double-voie : pour une image à niveaux de gris compris entre 0 et 255 par exemple, le niveau 0 correspond au signal (0,1) sur la paire des photodétecteurs, le 255 à (1,0), et le niveau 128 à (0.5,0.5) (voir fig.VII.13). Une idée astucieuse pour effectuer un tel codage sur une image à niveaux de gris consisterait à utiliser un OASLM (un modulateur de lumière adressé optiquement) qui permettrait de transformer une image en niveaux de gris en une image codée en polarisation après lecture de l'OASLM par un autre faisceau ; un prisme de Wollaston permettrait alors de scinder le faisceau issu de chaque pixel en deux contributions correspondant aux polarisations orthogonales. Finalement, une puce capable de traiter le problème de la détection du mouvement par l'algorithme de Dumontier aurait la même complexité que la puce à champ binaire en étude.

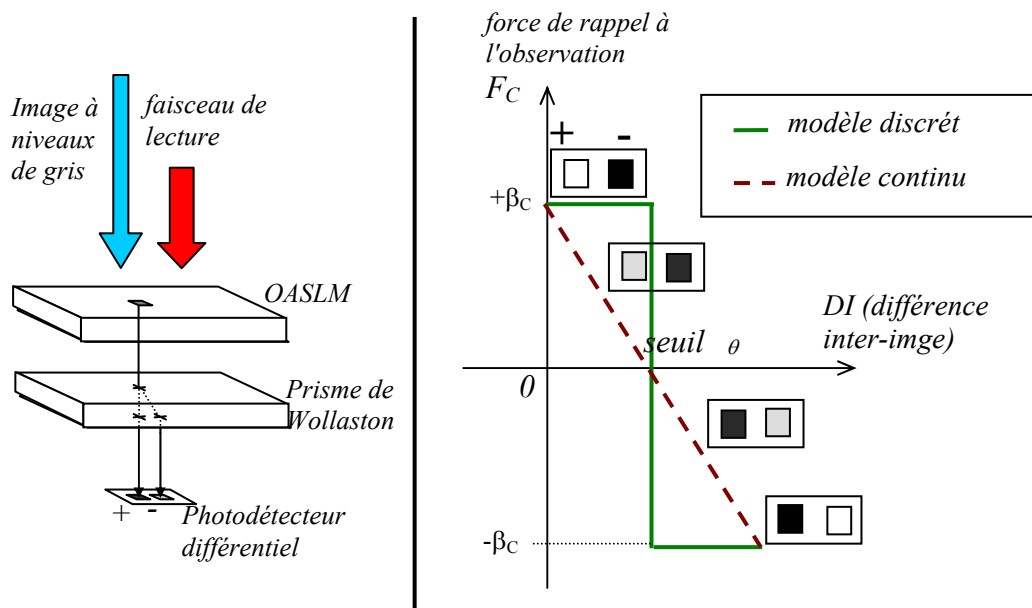


Fig.VII.13 : codage dual-rail d'images à niveaux de gris pour l'implantation optoélectronique de l'algorithme de Dumontier ou Lalande (voir Chap IV).

4.4 Estimation de la bande passante individuelle (BPO_i).

En supposant que la puissance optique n'est pas un facteur limitant, il ressort d'un calcul qui sera exposé en détail au §5.3, que la cadence maximale de fonctionnement - i.e. lecture, mise à jour et présentation du champ d'étiquettes sur les ports de sortie - d'un PPOS en technologie CMOS(0,7μm)-SEED est de **83,3** MHz, et cela quel que soit le système de voisinage et la taille de la matrice.

4.5 Estimation du nombre de transistors par PE (QI)

Le DCR comprend à peine deux transistors. Cependant, nous avons préféré majorer cette quantité en prévoyant une réalisation basée sur des récepteurs de type TIA. La cellule standard CMOS proposé par Lucent Technologies pour l'amplificateur différentiel à transimpédance (TIA), ainsi que celle de commande des modulateurs, comprennent

chacune une douzaine de transistors [Krish97a]. Le reste du circuit électronique du PE est de complexité équivalente à SPIE600. On évalue alors le QI du nouveau processeur à quelques 140 transistors par PE.

4.6 Conclusion

Une collaboration avec l'Université de Heriot-Watt à Edinburgh (Georg Clarici et Marc Demulliez au *Department of Computing and Electrical Engineering* et Brian Wherret au *Department of Physics*) a été envisagée en vue de réaliser le prototype de PPOS hybride, mais aujourd'hui, la réalisation de la matrice n'est pas programmée dans les agendas. Les éléments d'entrée-sortie de la puce seraient bien des paires de photodiodes PIN à MQW et le conditionnement du signal serait réalisée grâce à des amplificateurs à gain en tension. La surface totale d'un processeur élémentaire est estimé à $180 \times 180 \mu\text{m}^2$ en technologie CMOS $0,8 \mu\text{m}$, hypothèse justifiée dans la mesure où un démonstrateur de complexité équivalente a été fabriqué et testé à Heriot-Watt. Nous avons placé à titre de comparaison le nouveau prototype de PPOS en technologie CMOS-SEED dans les tableaux de mérites (*fig.VII.5* et *fig.VII.6*), le point correspondant porte l'étiquette PPOS/98.

5. Démonstrateur en technologie hybride CMOS-SEED.

5.1 Introduction

Le but de cette partie est d'étudier la faisabilité et les performances finales d'un système démonstrateur équivalent à celui proposé dans le Chap.V, mais dont l'élément central serait un SPA réalisé en technologie CMOS-SEED.

Il ressort d'une étude générale des systèmes optoélectroniques en technologie hybride OE-VLSI [Desmul99], que les principales contraintes de conception de systèmes utilisant des SPA soient (1) la limitation en puissance de la source optique et (2) la dissipation thermique (électrique) de la matrice. Pour une technologie VLSI donnée (CMOS 0,8 μ m, 0,5 μ m,...) et un choix du transducteur optoélectronique particulier (DCR, TIA, CSA,...), c'est donc par rapport à (1) et (2) qu'il faudra établir une estimation des performances théoriques du système. On commencera par une description sommaire de l'architecture optique proposée. On dressera ensuite le *bilan optoélectronique* qui nous va nous permettre de dériver les trois inéquations suivantes :

- Inéquation I (du bilan optique) : fréquence d'horloge maximale en fonction de la puissance optique disponible (il faut de l'énergie pour faire commuter les éléments de photodétection). Cette fréquence définit les performances maximales *off-chip*, i.e. la cadence maximale de commutation des portes optiques, et donc la BPO (bande passante optique).
- Inéquation II (du bilan électrique) : fréquence d'horloge maximale en fonction de la puissance électrique fournie à la puce (il faut de l'énergie pour faire fonctionner la partie logique du circuit). Cette fréquence maximale définit la performance maximale *on-chip*, i.e. la cadence maximale de commutation des portes électroniques, et donc la BPE (bande passante électrique).
- Inéquation III (des limitations thermiques) : la fréquence d'horloge maximale est limitée par la capacité de dissipation thermique de la puce (il ne faut pas griller le circuit, ni induire un mauvais fonctionnement des modulateurs, très sensibles aux variations thermiques). Cette dernière inéquation limite éventuellement la BPE et la BPO et donc la bande passante globale du système (BPG).

A partir de ces trois inéquations, on déduira la BPG du nouveau prototype. On pourra alors placer le système dans le tableau de mérite comparatif présenté au §2.4, et ceci pour le cas réaliste⁸⁵ d'une SPA comprenant $N_{PE} = 16 \times 32$ PEs

⁸⁵ Il faut comprendre le terme "réaliste" dans le sens de la conjoncture technologique actuelle : en 1999, les difficultés technologiques pour mettre en place des matrices CMOS-SEED comprenant entre 1000 et 5000 PE semblent être à peu près bien maîtrisées (Lucent Technologies).

5.2 Architecture optique

Comme il a été signalé auparavant, l'image à traiter (*l'observation* ou *terme de rappel*) peut être rentrée électroniquement ou optiquement sur la mémoire de la puce (cf. § 3.1). La deuxième option complique le montage optique. Par ailleurs le point critique est la rétroaction du champ d'étiquettes pendant le recuit ; le champ d'observation reste constant pendant toute la durée du traitement. Pour ces raisons, le montage qui sera étudié par la suite ne tient pas compte de l'optique supplémentaire liée à l'introduction de l'image à traiter. Il s'agit dans ce sens moins d'une rétine artificielle que d'un processeur dédié au recuit simulé, dont les interconnexions seraient réalisées optiquement (ce qui va plutôt dans le sens de la recherche sur les SPAs). En effet, on pourrait imaginer que le processeur utilise les interconnexions en espace libre pour communiquer avec un autre processeur équivalent et ainsi de suite ("cascadabilité" des puces) ; en l'occurrence il peut boucler sur lui même, comme c'est le cas dans notre application.




Fig.VII.14 : schéma de l'architecture optique pour le nouveau prototype de PPOS à entrées et sorties optiques. (AI pour Array Illuminator - illuminateur de tableau). L'image à traiter est rentrée électroniquement sur la SPA.

Une fois que l'image à traiter est chargée dans la puce (ou maintenue optiquement sur les ports d'entrée), la procédure de recuit est exécutée de la même façon que sur SPIE600, à ceci près que la *force locale de régularisation* sur chaque PE est calculée optiquement, par addition des sorties des PEs voisins. La mise à jour globale du champ

d'étiquettes se fait en N_C étapes, chaque étape correspondant à la mise à jour complète d'un domaine de couleur. Avant chaque mise à jour, une impulsion lumineuse de durée τ_0 éclaire *tous* les ports de sortie de la matrice (modulateurs), en épargnant les ports d'entrée. Ceci peut être réalisé grâce à un illuminateur de tableau (*AI* comme *Array Illuminator*) [Steib89], [Seyd91]. Le contenu de la matrice est ainsi 'lu' et le résultat convolué par un hologramme synthétique en réflexion avant d'être re-projeté sur celle-ci (fig.VII.14). Seul les PEs en mode de *détection* prennent en compte le signal optique résultant sur leurs ports d'entrée, afin de réaliser la *mise à jour* de l'étiquette binaire.

Remarque : Si les ports sont bidirectionnels (cf. remarque §4.1), alors il faudrait illuminer de façon périodique et *sélective* les différents domaines de couleur : pendant le cycle de lecture des PEs en mode modulation, le contenu individuel de chaque PE est projeté sur les photodétecteurs des voisins les plus proches *qui ne sont pas et ne doivent pas être éclairés par le faisceau de lecture*. Nous proposons plusieurs architectures pour construire le motif d'illumination ou *coloriage*.

(a) **Architecture avec un SLM.** Il s'agit du système représenté dans la fig.VII.15 : un SLM rapide génère le motif d'illumination. Une caractéristique intéressante de cette solution est la possibilité de disposer d'un coloriage reconfigurable à loisir. Si par ailleurs on utilise un deuxième SLM pour réaliser le motif d'interconnexion (à la place du CGH), alors on aura un système totalement reconfigurable (programmabilité des interconnexions et du voisinage). La complexité du système est équivalente au montage du *routeur* optique reconfigurable décrit dans [Moigna97]. Comme on peut l'imaginer, ce montage souffre de la limitation inhérente au temps de rafraîchissement du SLM (qui, rappelons le, était le principal facteur limitant les performances du démonstrateur précédent). Si l'on décrit ici cette option c'est principalement parce qu'elle pourrait être mise en application assez rapidement à partir du montage optique décrit dans le Chap.V.




Fig.VII.15 : Architecture optique dans le cas de ports bidirectionnels et/ou d'un coloriage contrôlé optiquement. Les PE sont alternativement en mode réception et d'émission.

(b) Architecture utilisant des illuminateurs de tableau. Une façon d'éviter le problème est d'utiliser toujours un illuminateur de tableaux ; mais chaque couleur serait commandé séparément par une diode laser différente. En effet, le motif de coloriage est le même pour toutes les couleurs - à une translation près. Il suffit donc de placer convenablement les sources pour lire l'hologramme illuminateur de tableau (fig.VII.16). Une matrice de lasers à cavité verticale pourrait très bien servir à rendre le système compact.

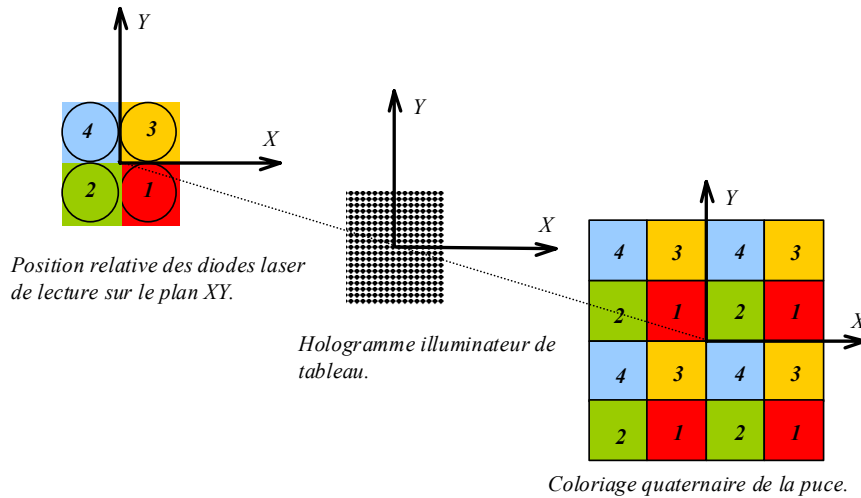


Fig.VII.16 : Placement des diodes laser de lecture dans le cas du coloriage quaternaire. Le motif d'illumination pour la mise à jour de chaque couleur est le motif complémentaire du motif de coloriage (il faut illuminer le voisinage de la couleur traitée).

(c) Une autre possibilité intéressante est illustrée dans la fig.VII.17 et s'inspire d'une approche optoélectronique permettant de reconfigurer une *FPGA* (pour *Field Programmable Gate Arrays*) qui devient alors une *OPGA* (pour *Optically Programmable Gate Arrays*) [Mumbru00]. L'idée consiste à utiliser des mémoires holographiques (hologrammes plans ou en volume) pour configurer rapidement la matrice optoélectronique. On a récemment démontré que l'on peut stocker jusqu'à une centaine d'hologrammes avec un *cross-talk* faible et une bonne efficacité de diffraction en utilisant la technique de *shift & spatial multiplexing* [Mumbru99]. Ce type de montage réunirait alors les avantages du système à SLM et la rapidité de modulation des lasers semi-conducteurs.




Fig.VII.17 : Montage utilisant des un système de coloriage $\{C_1, C_2, C_3, C_4\}$ enregistré sur mémoire holographique et commandé une matrice linéaire de VCSEL.

Remarquons enfin que toutes ces architectures envisagées permettraient de simplifier encore plus la conception de la partie logique de la puce optoélectronique si l'on choisissait de fournir l'horloge par voie optique. On pourrait adopter la stratégie suivante : un PE n'effectuerait sa mise à jour que quand il se trouve dans *l'ombre* par rapport au motif de lecture. Le signal de mise à jour, normalement fourni de façon électronique, pourrait donc être remplacé par une simple détection seuillée d'intensité. Encore faudrait-il pourvoir le PE d'un photodétecteur additionnel, à moins de choisir de perdre un cycle d'horloge pour "préparer" les processeurs à leur mise à jour. Du coup, il n'y aurait plus besoin de signaux de contrôle pour la programmation de couleurs, ni d'horloge commune.

5.3 Bilan optoélectronique

5.3.1 Définition des grandeurs optoélectroniques.

Avant d'aborder le calcul des performances, nous avons besoin de définir un certain nombre de grandeurs caractéristiques du système optoélectronique. La méthodologie d'étude est fortement inspirée des travaux menés à l'Université de Heriot-Watt. On trouvera dans [Desmul99] une étude générale des systèmes optoélectroniques OE-VLSI.

Paramètres généraux:

N_{PE} : nombre de processeurs élémentaires (PE) de la matrice.

Q : puissance maximale dissipée par la matrice, en forme de chaleur (W/cm^2)

Grandeurs électriques :

F_{clock} : fréquence d'horloge électronique de la puce (définie comme la cadence de mise à jour des partitions en couleur du champ d'étiquettes) ; T_{clock} est la période d'horloge correspondante.

F_C : fréquence d'horloge de couleur : c'est la cadence de mise à jour d'une quelconque partition du champ d'étiquettes. Si N_C est le nombre de partitions ou couleurs (nombre chromatique du voisinage), alors $F_C = F_{clock} / N_C$.

F_{iter} : fréquence de mise à jour du champ d'étiquettes tout entier (i.e. une *itération*). On a tout simplement $F_{iter} = F_C$, puisque la mise à jour des partitions couleur se fait de façon séquentielle et périodique.

P_e : puissance électrique disponible sur la puce.

ΔE_e : énergie nécessaire pour réaliser la commutation d'une porte logique CMOS et la charge d'une interconnexion métallique dans le circuit VLSI.

N_{e-PE} : nombre de portes logiques par PE.

T_{elec} : temps imparti à chaque PE pour réaliser la totalité du traitement logique. T_{elec} peut être supérieur à T_C , mais on a toujours $T_{elec} \leq T_{clock}$.

Grandeurs opto-électroniques :

T_{IN} : temps nécessaire pour convertir et conditionner le signal optique arrivant sur la paire de détecteurs du PE en niveau électrique logique. C'est la somme du temps d'intégration du détecteur différentiel (T_{conv}) et du temps d'amplification du signal (T_{amp}) jusqu'au niveau logique.

ΔE_{min} : Energie minimum nécessaire pour convertir un signal optique sur les détecteurs différentiels en signal logique. On a $\Delta E_{min} = C_{in} \Delta V_{in} / S \approx 0,15$ pJ (pour le détecteur différentiel présenté au §4.2).

$N_{o-PE(IN/OUT)}$: nombre de portes optiques (IN) d'entrée et (OUT) de sortie par PE.

T_{OUT} : temps nécessaire pour charger la paire de modulateurs de sortie.

Grandeurs optiques :

P_{tot} : puissance optique de la source.

τ_o : durée de l'impulsion lumineuse de lecture. Elle est donnée par la durée de l'impulsion de lecture de la diode laser en mode Q-CW.

T_{vol} : temps de vol maximal des signaux optiques en espace libre.

η_{S-PE} : efficacité de la liaison entre source de lecture et *chaque* modulateur individuel. Elle intègre la répartition de l'énergie totale entre tous les PE ainsi que les pertes associés au système d'imagerie (la transmission du SLM pour (A), l'efficacité de diffraction $\eta_{fan-out}$ de l'hologramme illuminateur de tableaux pour (B), les pertes d'insertion –voir Chap.VI- et les pertes globales des composants optiques).

η_{PE-PE} : efficacité de la liaison entre un PE source et un PE récepteur. Cette quantité intègre entre autres l'efficacité de diffraction de l'hologramme responsable du voisinage par convolution η_{vois} , les pertes des composants optiques et les pertes d'insertion.

C et R_{ON} : les modulateurs à MQW présentent un contraste variant entre 1,5 et 2:1. Pour poursuivre notre étude on prendra la pire des valeurs pour le contraste : $C=1,5$. La réflectivité à l'état passant est de l'ordre de $R_{ON}=70\%$.

5.3.2 Bilan Optique.

Le but de ce paragraphe est d'obtenir une borne supérieure pour la fréquence d'horloge en fonction de la puissance optique totale fournie au système, P_{tot} . Pour cela, on va chercher à déterminer la puissance optique disponible au niveau de la matrice après que le faisceau source ait traversé tous le système optiques.

Puissance optique de la source : P_{tot} .

Le mode d'opération de la source optique d'alimentation du système peut être continu (CW) ou quasi-continu (Q-CW). Le deuxième mode se prête naturellement à notre application, puisqu'il faut éclairer les PE de façon intermittente. En dernier ressort, le mode de fonctionnement dépendra de la puissance optique consommée par le système,

quantité qui est fonction à son tour de la cadence d'horloge et du nombre de pixels de la puce. Ce sont précisément les paramètres de performance que l'on va tenter d'estimer par la suite.

Si l'on se limite - pour des raisons de compacité et de coût - à l'utilisation de diodes laser continues comme source optique, alors il semblerait que le maximum de puissance plafonne aujourd'hui autour du Watt. Les modulateurs à puits quantiques en InGaAs utilisés dans les démonstrateurs de l'Université de Heriot-Watt fonctionnent à la longueur d'onde de 1047nm, ce qui permet d'utiliser des laser compacts quasi-CW pompés par diode de type Nd:YLF [Yu93a], d'une puissance supérieure au Watt (ce qui constitue un avantage immédiat par rapport aux modulateurs en AlGaAs d'AT&T).

Pour fixer les idées, on posera cependant $P_{tot} = 1W$. Cette quantité sera donc la puissance optique globale et maximale disponible dans le système pour réaliser la lecture et la mise à jour de l'ensemble des PEs.

Pertes optiques et puissance optique disponible pour la commutation

On s'intéresse ici au quantum de puissance optique minimal p_{min} qu'un port optique d'entrée - i.e. une paire différentielle de photodiodes p-i(MQW)-n - doit être en mesure de détecter. Considérons le $PE(i)$ situé au site i de la matrice. Alors p_{min} est donné par la différence de puissance incidente sur la paire de photodétecteur du $PE(i)$ quand *un seul* des ports de sortie $PE(j)$ du voisinage $V(i)$ commute entre l'état ON et l'état OFF.




Fig.VII.18 Calcul de la puissance optique incidente sur un photodétecteur. La puissance arrivant sur le modulateur provient de l'illuminateur de tableau.

Soit $v=card(V)$ le cardinal du voisinage, et $e_j \in \{0,1\}$ l'état du voisin $PE(j)$ du processeur élémentaire $PE(i)$. Soit $p_m(j)$ la puissance optique incidente le modulateur + (respectivement -) de la paire de modulateurs de sortie du $PE(j)$ (c'est la puissance du faisceau de lecture sur chaque PE en cycle de modulation). Soit $p_d(i)$ la puissance optique arrivant sur le détecteur + (respectivement -) du $PE(i)$, résultant de la convolution optique du signal issu de $PE(j)$ par l'hologramme synthétique d'efficacité η_{inter} sur l'ordre utile - voir fig.VII.18

On a tout d'abord, (en supposant l'illumination uniforme sur la puce) :

$$p_m(j) = \eta_{S-PE} P_{tot}, \forall j \in V(i)$$

Si l'état du modulateur + (resp. -) du PE(j) est ON : $p_d^{ON}(i) = \eta_{PE-PE} \cdot R_{ON} \cdot p_m$,

$$\dots \text{et si l'état est OFF : } p_d^{OFF}(i) = \frac{p_d^{ON}(i)}{C} = \eta_{PE-PE} \cdot \frac{R_{ON}}{C} \cdot p_m$$

La force locale au site i est calculée de façon différentielle ; en soustrayant les contributions positives et négatives des sites voisins, il vient immédiatement que la force optique différentielle est proportionnelle à la quantité :

$$p_{opt}(i) = (p_d^{ON} - p_d^{OFF}) \cdot \sum_{j \in V(i)} (2e_j - 1) = p_d^{ON} \left(1 - \frac{1}{C}\right) \cdot \sum_{j \in V(i)} (2e_j - 1).$$

La plus petite variation (en valeur absolue) de cette puissance est donnée par l'incrément

$$\Delta p(i) = 2 \cdot p_d^{ON} \left(1 - \frac{1}{C}\right), \text{ résultant de la commutation d'un seul PE du voisinage.}$$

La puissance optique minimale qu'un PE doit être en mesure de détecter est donc, en fonction de P_{tot} :

$$p_{min} = 2 \cdot \eta_{S-PE} \cdot \eta_{PE-PE} \cdot R_{ON} \left(1 - \frac{1}{C}\right) P_{tot}.$$

Pour une puissance optique d'1W, p_{min} varie entre 52 μ W pour un voisinage 4, 28 μ W pour un voisinage 8 et 24 μ W pour un voisinage d'ordre 3 aux 12 plus proches voisins.

Temps de conversion opto-électronique

Soit τ_o la durée de l'impulsion du faisceau de lecture ; la détection du "quantum" de force optique p_{min} n'est possible que si :

$$p_{min} \cdot \tau_o \geq \Delta E_{min} = \frac{1}{S} C_{in} \cdot \Delta V_{in},$$

C_{in} est la capacité totale formée par les détecteurs, les connexions électriques flip-chip (*bonding pads*), et la capacité d'entrée du transistor. ΔV_{in} est la variation de tension à l'entrée de l'amplificateur nécessaire pour faire commuter le niveau logique de sortie de la quantité ΔV_{log} . Dans ces conditions, le temps de conversion du signal optique est tout simplement donné par :

$$\tau_o = T_{conv} \equiv \frac{C_{in} \cdot \Delta V_{in}}{S \cdot p_{min}}$$

(si $\tau_o < T_{conv}$, alors le signal n'est pas détecté). Ce temps correspond à la durée *minimale* de l'impulsion de lecture. Pour une puissance optique d'1 W, on aura τ_o entre 3 et 6 ns (en fonction du système de voisinage choisi). En pratique, pour le DCR de la fig.VII.11, il suffit que 75% du courant photoinduit soit présent pour *commencer* l'amplification ; en effet, le temps de conversion du signal optique en signal logique (électronique) est donné par [Lentin94]:

$$T_{IN} = T'_{conv} + T'_{amp} = \frac{3}{4} \frac{C_{in} \cdot \Delta V_{in}}{S \cdot p_{min}} + 2 \cdot C_{out} \cdot \frac{\Delta V_{log}}{g_m \cdot \Delta V_{in}},$$

(toujours à condition que $\tau_0 \geq T_{conv}$, sinon le signal n'est pas détecté). g_m est la transconductance de l'amplificateur et C_{out} sa capacité de sortie.

La sortie optique du PE peut être réalisée simplement grâce à un inverseur chargeant une paire de modulateurs. Les états de haute (ON) ou basse (OFF) réflectivité sont assurés par application de la tension V_O aux bornes des diodes MQW. Le temps T_{OUT} requis pour atteindre cette tension est :

$$T_{OUT} = 2 \cdot \frac{C_{ex} \cdot V_o}{\Delta I_{trans}},$$

(à condition qu'ils ne soient pas éclairés pendant leur mise sous tension - ce qui est bien le cas puisque ils sont entièrement à l'ombre par rapport aux signaux de lecture produit par l'AI). Dans la formule, C_{ex} est la capacité de sortie du circuit électronique et ΔI_{trans} le courant de sortie chargeant cette capacité. Ce temps est de l'ordre de la dizaine des picosecondes et peut être négligée par rapport aux autres quantités.

Temps total de traitement

Le temps total de traitement optoélectronique d'un PE est donné par la somme du temps total de conversion des signaux (optique-électronique et électronique-optique) et du temps de traitement purement électronique ou temps de calcul :

$$T_{PE} = T_{IN} + T_{elec} + T_{OUT}$$

Le reste du temps, le PE est inactif. On définit le *temps d'oisiveté* T_{ois} comme le temps pendant lequel *aucun* des PE de la matrice ne travaille :

$$T_{ois} = T_{clock} - T_{PE} \text{ (voir chronogramme fig.VII.19).}$$

T_{elec} est donné par des simulations de type SPICE ; il est de l'ordre de la dizaine de nanosecondes⁸⁶ pour des circuits CMOS de complexité comparable.

Le temps de traitement optoélectronique T_{PE} , plus le temps de vol T_{vol} des signaux optiques doit être inférieur au cycle d'horloge (cf. fig.VII.19) :

$$T_{PE} + T_{vol} \leq T_{clock} = \frac{1}{F_{clock}}$$

Cette condition peut être exprimée comme une contrainte sur la puissance optique nécessaire au bon fonctionnement de la matrice pour une fréquence d'horloge donnée :

Inéquation (I) :

$$P_{opt} = \frac{3}{8} \cdot \frac{\Delta E_{min}}{\eta_{S-PE} \cdot \eta_{PE-PE} \cdot R_{ON} \cdot \left(1 - \frac{1}{C}\right)} \left[\frac{1}{F_{clock}} - \frac{1}{F_{MAX}} \right]^{-1} \leq P_{tot}$$

⁸⁶ Remarque importante : l'approche SPA n'est justifiée par rapport aux processeurs classiques que si l'on peut tirer profit de l'énorme bande disponible. En d'autres termes, il faut que le temps de traitement électronique, T_{PE} soit au maximum de l'ordre du temps de conversion du signal optique. C'est tout à fait le cas de notre processeur stochastique, puisque le traitement logique se résume en gros à une comparaison!

où $F_{MAX} = \frac{1}{T_{amp} + T_{elec} + T_{OUT} + T_{vol}} \approx 83MHz$ est une borne supérieure pour la fréquence,

indépendante de la puissance optique disponible et caractérisant le circuit électronique et l'architecture optique (fréquence de coupure du système).




Fig.VII.19 : Chronogramme de deux PE voisins pour le cas du coloriage binaire. Le faisceau de lecture généré par l'illuminateur de tableau (AI) et la diode laser est représenté par le signal carré ; il n'est pris en compte par un PE que si celui-ci se trouve en cycle de détection.

Remarque : le produit $R_{ON}(1-1/C)$ caractérise les propriétés optiques des modulateurs. Il vaut environ 0,2 pour les modulateurs étudiées ($C \approx 1,5:1$ et $R_{ON} \approx 70\%$). Il est concevable que l'on puisse améliorer sensiblement le contraste (empilement de modulateurs, cavité Fabry-Pérot). Pour un composant idéal, on aurait $C = \infty$ et $R_{ON} = 100\%$ et donc $R_{ON}(1-1/C) = 1$: la puissance nécessaire P_{opt} serait seulement divisée par cinq (1/0,2). (Cependant, comme on peut le voir dans la fig.VII.20, le point de fonctionnement du système se trouve déjà dans la partie exponentielle de la courbe $P_{opt} = f(F_{clock})$: il n'y aura pas de changement drastique de la cadence maximale de fonctionnement du système. La zone de linéarité de la courbe est centrée sur $F_{clock} = F_{MAX} / 2$; c'est donc d'abord sur F_{MAX} (circuits convertisseurs et de calcul) qu'il faudra jouer pour que les performances du système augmentent sensiblement avec la qualité des modulateurs.

Le temps de vol des signaux optiques est inférieur à la nanoseconde pour des montages compacts n'excédant pas la dizaine de centimètres. Le facteur limitant la fréquence d'horloge est donc le temps d'intégration T_{conv} des photodétecteurs, quantité qui varie fortement en fonction de la puissance du laser de lecture. Ce terme ne peut pas être rendu aussi petit que l'on voudrait car (1) la puissance optique de la source est limitée (par hypothèse à 1W), et (2) le circuit doit être capable de dissiper la chaleur dégagée, quantité qui est proportionnelle à la fréquence d'horloge. Le *tab.VII.4* donne un ordre de grandeur de ces diverses durées.

Enfin, la BPO_i du PE est tout simplement égale à la fréquence d'horloge de couleur F_C . Par exemple, s'il n'y a pas de limitation en puissance optique et si l'on prévoit une interconnexion holographique aux 8 plus proches voisins (donc $N_C=4$) on obtient alors une BPO_i égale à $83,3\text{MHz}/4 \approx 21 \text{ MHz}$.

Définition	Symbole	Valeur typique
temps de vol des signaux optiques	T_{vol}	1 ns
temps de conversion optoélectronique	T_{in}	3 / 4,5 / 5,3 ns (pour $P_{tot}= 1\text{W}$ et une interconnexion aux 4, 8 et 12 voisins respectivement)
temps de calcul électronique	T_{elec}	10 ns
temps de conversion élec.-opt.	T_{out}	1 ps
Temps total de traitement	T_{PE}	13 / 14,6 / 15,4 ns (pour $P_{tot}= 1\text{W}$ et une interconnexion aux 4, 8 et 12 voisins respectivement)

Tab.VII.4 : temps caractéristiques de traitement optoélectronique pour la puce PPOS en technologie CMOS-SEED.

Remarque. L'observation du chronogramme laisserait supposer un gain en parallélisme si l'on pouvait disposer du temps pendant lequel le PE se trouve en mode modulation. Il n'en est rien : la rupture du parallélisme est inhérente à l'algorithme de relaxation, et on ne peut pas dépasser le pourcentage d'activation des PE cité auparavant $k=1/N_C$. Le mieux que l'on puisse faire c'est d'annuler le temps deoisiveté, T_{ois} , c'est à dire faire $T_{clock}=T_{PE}+T_{vol}$.

Par contre, une architecture en *pipe-line* sur chaque PE permettrait de traiter jusqu'à N_C images en même temps, et d'exploiter ainsi le parallélisme complet du système (on remarque toutefois qu'il n'y aurait pas de gain en vitesse pour le traitement d'une image individuelle). Il faudrait pour cela rajouter N_C points mémoire dans chaque PE, chacun correspondant à un champ de relaxation différent. Les modulateurs seraient constamment illuminés et leur convolution projeté continûment sur les détecteurs voisins. A la différence du système précédent, le

contenu des modulateurs changerait à chaque cycle d'horloge, en affichant consécutivement le contenu de la chaîne mémoire *pipe-line*. Aussi, le champ d'observation ne serait plus constant, ni pendant le recuit, ni pendant la durée de la relaxation à chaque palier de température. Il changerait à chaque impulsion d'horloge ; il serait subdivisé en pixels de couleur de telle sorte que le pixel de couleur k contienne le pixel correspondant de l'image k . Comme il n'y a pas de modulateur spatial de lumière capable de projeter un champ variant si rapidement, l'entrée de l'image de façon électronique semble être la seule solution valable. Cependant, à moins d'utiliser une mémoire supplémentaire pour rentrer une image entrelacée de taille N_C fois plus grande que la taille de la puce (une fois l'image rentrée, il suffirait d'un système de décalage sur X et Y pour assurer la bonne correspondance entre couleurs), la solution électronique ferait malheureusement perdre beaucoup plus de cycles d'horloge que si l'on se borne au parallélisme partiel ($k=1/N_C$).

Il existe une seule situation dans laquelle la solution pourrait être intéressante : les N_C images à traiter sont la même, ce qui signifie que le champ d'observation est constant. Les N_C recuits donneront à coup sûr des résultats différents, mais ces différents champs peuvent se combiner pendant le recuit et accélérer la procédure de convergence (chaînes de Markov concurrentes à la même température ou algorithme *de division* - cf. Chap.II, §2.2.7).

5.3.3 Bilan électronique.

Le but de ce paragraphe est de déterminer une borne supérieure pour la fréquence d'horloge en fonction de la puissance électrique P_e disponible sur la puce (inéquation II).

Pendant le cycle de calcul (de durée T_{elec}), le fonctionnement *dynamique* du circuit CMOS consomme une puissance électrique par PE de :

$$P_{elec-PE} \approx \frac{N_{e-PE} \cdot \Delta E_e}{T_{elec}}$$

où N_{e-pe} est le nombre de portes logiques du PE, ΔE_e est l'énergie nécessaire à leur commutation individuelle. L'expression donnée ci-dessus est approximative et correspond à l'hypothèse que *toutes* les portes électroniques du PE commutent *une* fois pendant le cycle de calcul ; on suppose aussi que le circuit CMOS ne consomme pas de l'énergie en fonctionnement statique. Cette quantité, en gros proportionnelle à la fréquence de fonctionnement du circuit ($1/T_{elec}$) est mieux déterminée par des simulations (SPICE).

Si l'on suppose qu'un PE en cycle de modulation ne consomme pas d'énergie électrique, alors la puissance moyenne électrique consommée par chaque PE pendant un cycle

d'horloge est :

$$\langle P_{elec-PE} \rangle = \frac{F_{clock}}{N_C} P_{elec-PE} \cdot T_{elec} \approx \frac{F_{clock}}{N_C} \cdot N_{e-PE} \cdot \Delta E_e,$$

puisque un PE "s'active" seulement tous les N_C cycles d'horloge. A partir de cette quantité, on peut exprimer la puissance électrique moyenne consommée *en continu* par la matrice :

$$P_{elec} = N_{PE} \cdot \langle P_{elec} \rangle = N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot P_{elec-PE} \cdot T_{elec} \approx N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot N_{e-PE} \cdot \Delta E_e$$

L'expression exacte est utile à condition de connaître T_{elec} et $P_{elec-PE}$, résultats de la simulation du circuit (SPICE). Par exemple, pour le *Bitonic-Sorter* de Heriot-Watt [Walker98], on a T_{elec} de l'ordre de 10ns et $\partial P_{elec-PE}/\partial F_{elec}=24\mu W/MHz$. Donc, $P_{elec-PE}=2,4mW$.

La puissance électrique fournie à la puce est P_e ; elle est suffisante pour permettre la commutation des portes de toute la matrice à la fréquence d'horloge F_{clock} à condition que $P_{elec} \leq P_e$. D'où :

$$\text{Inéquation II : } \boxed{P_{elec} = N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot P_{elec-PE} \cdot T_{elec} \leq P_e}$$

La source électrique n'est pas un facteur limitant du système (sauf pour des applications qui nécessiteraient une faible consommation d'énergie électrique). Cependant, la puissance électrique fournie peut être limitée par la capacité de dissipation thermique de la matrice.

5.3.4 Limitations thermiques

La puissance maximale que la matrice est capable de dissiper par cm^2 , Q , est l'ordre de $10W/cm^2$. Il s'agit d'une borne assez prudente : elle correspond à la puissance dissipée par les microprocesseurs commercialisées aujourd'hui ($12-15W/cm^2$ pour les Pentium de dernière génération). Ce sont des puces de taille comparable ($140mm^2$ pour le Pentium P55C-MMX) mais de complexité bien supérieure à celle de notre SPA. Remarquons aussi que les modulateurs à puits quantiques sont particulièrement sensibles aux variations thermiques (déplacement du pic de modulation de l'ordre de $0.3nm/^\circ C$).

La puissance dissipée par la matrice optoélectronique est la somme de la puissance dégagée par la conversion optoélectronique (circuits transducteurs) et de celle produite par le circuit logique CMOS :

$$Q_{TOT} = Q_{OPTOELEC} + Q_{ELEC}$$

1) Calcul de $Q_{OPTOELEC} = Q_{IN} + Q_{OUT}$ (circuits transducteurs) :

Chaleur dissipée pendant la photodétection : Q_{IN} . La puissance optique incidente sur les photodétecteurs provient du speckle laser et de la force optique calculé par convolution. Pour prendre le pire des cas, on considérera que la puissance optique provenant des PE voisins ainsi que du générateur de speckle sont maximales :

(a) La puissance (différentielle) maximale provenant de la convolution est réalisée quand tous les voisins ont la même valeur. En valeur absolue, celle ci correspond a :

$$p_{optMAX}(i) = (p_d^{ON} - p_d^{OFF}) \cdot \sum_{j \in V(i)} \left(2e_j \Big|_{e_j=1} - 1 \right) = v \cdot p_d^{ON} \left(1 - \frac{1}{C} \right)$$

Soit encore, en fonction de la puissance optique de la source P_{tot} :

$$P_{optMAX} = v \cdot \eta_{S-PE} \cdot \eta_{PE-PE} \cdot \left(1 - \frac{1}{C}\right) P_{tot}$$

(b) La source de speckle est indépendante de P_o . Néanmoins, supposer que l'intensité de speckle est *maximale* veut dire que les PE commutent aléatoirement : il serait inutile de fournir à la puce un speckle plus fort. En d'autres termes, la quantité que l'on cherche est de l'ordre de P_{optMAX} .

En somme, la puissance maximale différentielle qu'un photodétecteur peut recevoir est :

$$p_{MAX} = 2 \cdot v \cdot \eta_{S-PE} \cdot \eta_{PE-PE} \cdot \left(1 - \frac{1}{C}\right) P_{tot}$$

Cette puissance est responsable de faire varier la sortie des photodétecteurs d'une quantité ΔV_{in} . La durée de conversion dépend bien sûr de la puissance optique incidente sur le photodétecteur. Puisque l'on ne contrôle pas *séparément* le temps de lecture minimum pour chaque PE, on doit considérer le pire des cas, c'est à dire un temps τ_o de lecture au moins aussi long que le temps T_{conv} nécessaire à la détection du quantum minimum p_{min} de puissance optique, tout en considérant que la puissance optique incidente est *maximale* sur tous les PEs.

La puissance dissipée lors de la charge ΔV_{in} du condensateur de sortie des photodétecteurs est, par PE, égale à [Yu93b] :

$$P_{IN}^1 = 2 \int_0^{\Delta V_{in}} I_{ph} \cdot dV = 2 \cdot S \cdot p_{MAX} \cdot \Delta V_{in},$$

où $I_{ph} = S \cdot p_{MAX}$ est le courant photoinduit par la puissance optique p_{max} , supposée constante pendant toute la durée d'intégration T_{conv} . Le faisceau de lecture est maintenu encore pendant une durée $\tau_o - T_{conv}$ sur l'étage d'entrée qui se trouve alors sous une tension constante ΔV_{in} . La puissance dégagée pendant cette durée est alors :

$$P_{IN}^2 = \frac{P_{IN}^1}{2} = S \cdot p_{MAX} \cdot \Delta V_{in}$$

La puissance dissipée par la photodétection, moyennée sur les PE de la matrice, et pendant un cycle d'horloge est alors :

$$\langle P_{IN} \rangle = \frac{P_{IN}^1 \cdot T_{conv} + P_{IN}^2 \cdot (\tau_o - T_{conv})}{N_C \cdot T_{clock}}$$

où $F_C = 1/(N_C \cdot T_{clock})$ est la cadence de mise à jour de chaque PE individuel. On remarque que le premier terme de la somme est indépendant de P_o , (ce qui est normal, puisque l'énergie de commutation est constante), et vaut :

$$P_{IN}^1 \cdot T_{conv} = 2 \cdot S \cdot p_{MAX} \cdot \Delta V_{in} \cdot \frac{C_{in} \cdot \Delta V_{in}}{S \cdot p_{min}} = 2 \cdot v \cdot C_{in} \cdot \Delta V_{in}^2$$

Enfin, la puissance optique moyenne dissipée en continu par la matrice toute entière :

$$Q_{IN} = N_{PE} \cdot \langle P_{IN} \rangle$$

Si l'on suppose que le faisceau de lecture peut être éteint dès que la conversion est finie ($\tau_o = T_{conv}$), il vient :

$$Q_{IN} = N_{PE} \cdot \frac{v}{N_C} \cdot F_{clock} \cdot C_{in} \cdot \Delta V_{in}^2.$$

Chaleur dissipé pendant la lecture des modulateurs : Q_{OUT} .

Pendant le cycle de lecture la puissance incidente est constante et vaut :

$$P_m = \eta_{S-PE} P_{tot},$$

Les modulateurs sont sous tension (V_o) pendant la durée de lecture. Si l'on suppose toujours que $\tau_o = T_{conv}$, (le temps de lecture est égal au temps d'écriture, puisque c'est le temps nécessaire pour qu'un photodétecteur puisse lire le signal du PE voisin), alors la puissance moyenne dissipée par l'étape de lecture -par PE et pendant un cycle d'horloge- est :

$$\langle Q_{OUT} \rangle = \frac{2 \cdot P_m \cdot S \cdot V_o \cdot T_{conv}}{N_C \cdot T_{clock}},$$

(le facteur 2 indique que le faisceau de lecture est incident sur les deux modulateurs). La puissance moyenne dissipé par la matrice entière due à la lecture des données est :

$$Q_{OUT} = 2 \cdot v \cdot N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot C_{in} \cdot \Delta V_{in} \cdot V_o,$$

Finalement :

$$Q_{OPTOELEC} = Q_{IN} + Q_{OUT} = N_{PE} \cdot \frac{v}{N_C} \cdot C_{in} \cdot \Delta V_{in} \cdot (\Delta V_{in} + V_o) \cdot F_{clock}$$

2) Calcul de Q_{ELEC} (circuit logique CMOS).

La puissance dissipée par le circuit CMOS est égale à la puissance électrique consommée par la puce :

$$Q_{ELEC} = P_{elec} = N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot P_{elec-PE} \cdot T_{elec} \approx N_{PE} \cdot \frac{F_{clock}}{N_C} \cdot N_{e-PE} \cdot \Delta E_e$$

Finalement, la chaleur dissipée moyenne Q_{TOT} doit être inférieure à $Q \cdot S_{puce}$, où S_{puce} est l'aire de la puce optoélectronique : $S_{puce} = S_{PE} \cdot N_{PE}$, avec $S_{PE} = 400 \times 200 \mu m^2$:

$$Q_{TOT} = Q_{ELEC} + Q_{OPTOELEC} \leq Q \cdot S_{puce}, \text{ d'où}$$

Inéquation III:

$$Q_{TOT} = F_{clock} \cdot \frac{N_{PE}}{N_C} \cdot \{v \cdot C_{in} \cdot \Delta V_{in} \cdot (\Delta V_{in} + V_o) + P_{elec-PE} \cdot T_{elec}\} \leq Q \cdot S_{puce}$$

5.4 Tableaux de mérite système et performances finales.

Les inéquations II et III dépendent des caractéristiques du circuit électronique (surface, performance des circuits de conversion et calcul, mais aussi voisinage d'interconnexion et nombre de PEs fonctionnels, etc.) et de la puissance électrique disponible. L'inéquation I dépend en outre de la puissance *optique* disponible sur la matrice et donc indirectement des divers facteurs d'atténuation optique propres à l'architecture optique. Toutes ces quantités sont prises en considération dans l'expression de η_{S-PE} et de η_{PE-PE} . Pour l'architecture proposée utilisant un système à illuminateur de tableau, $\eta_{S-PE} = \eta_{fan-out} / N_{in}$, où N_{in} est le nombre de plots de connexion optiques d'entrée (c'est à dire $N_{in} = 2N_{PE}$ pour le PPOS) et $\eta_{fan-out}$ est l'efficacité de l'AI. On prendra pour cette dernière la valeur assez prudente de 40% (pour un réseau de Dammann ; pour un AI à effet Talbot, on a démontré des efficacités allant jusqu'à 70% [Seyd91]).

On est enfin en mesure de représenter graphiquement les trois inéquations (fig.VII.21). Nous avons pris comme exemple une matrice 16x32 PEs, similaire au module *Exchange-Bypass* du *Bitonic-Sorter* de l'équipe de Heriot-Watt [Walker98]. On constate que le système est limité par la puissance optique de la source (tout comme le démonstrateur de Heriot-Watt). Il est important de remarquer que la puissance optique consommée est proportionnelle au nombre de PEs en fonctionnement, soit à la surface utile de la puce. La cadence de fonctionnement reste très inférieure à la fréquence de modulation dont est capable une diode laser q-CW (de l'ordre du GHz, pour des pics d'une durée inférieure à la trentaine de picosecondes [Vasile93]), ce qui valide leur utilisation pour le système à illuminateurs de tableau (il faut que la cadence de répétition soit de l'ordre de la centaine de MHz, pour des impulsions d'une durée τ_0 entre à 3 et 6 ns), et aussi l'éventualité d'un contrôle optique du coloriage.

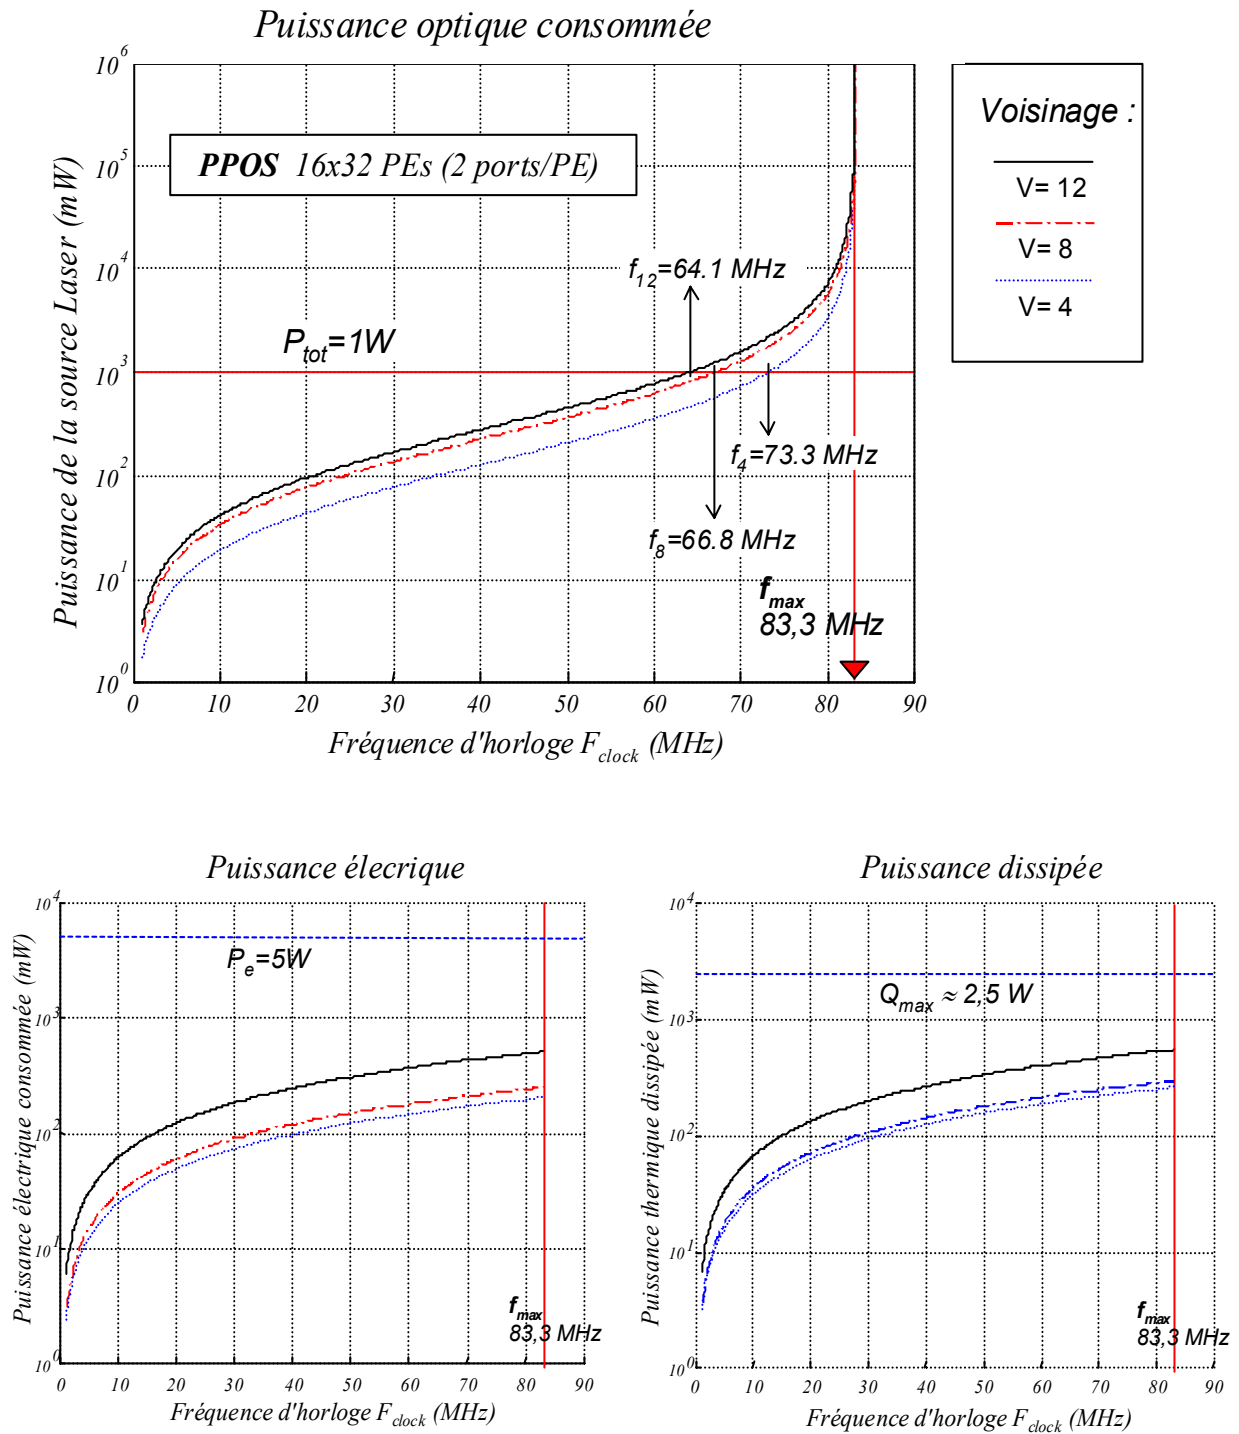


Fig.VII.s : Bilan optoélectronique pour l'architecture à illuminateur de tableau. Le système est limité en puissance optique. La cadence maximale d'horloge vaut 73,3 MHz, 66,8 MHz et 64,1 MHz pour les systèmes à interconnexions aux 4, 8 et 12 voisins respectivement.

Tableau de mérites. En conclusion au §2.5, il a été dit que l'on devait s'attendre à des *BPG* dépassant le GHz pour des systèmes utilisant des SPA réalisés grâce à la technologie CMOS-SEED actuelle (*tab.VII.1*). Qu'en est-il en réalité? Nous avons estimé les mérites *système*, du nouveau prototype en considérant une matrice comportant $N_{PE}=16 \times 32$ PEs (les points correspondants sont notés $PPOS_{4/8/12}$ selon le système de voisinage - voir *fig.VII.7* et *fig.VII.8*). La bande passante optique individuelle (BPO_i) est tout simplement égale à la fréquence d'itération (fréquence de mise à jour du de la totalité du champ d'étiquettes) $F_{iter}=F_C=F_{clock}/N_C$. La bande passante (optique) globale est donc égale à $BPG=2 \times N_{PE} \times V \times BPO_i$ (2 ports par PE et V interconnexions par port). Comme prévu, la *BPG* du prototype est légèrement supérieure à la centaine de GHz.

Nombre de recuits sérieux à la seconde. Nous avons estimé au §3.2 (*tab.VII.2*) que l'utilisation de la technologie hybride CMOS-SEED permettrait d'atteindre 150.000 recuits sérieux à la seconde (1000 mises à jour pour chaque couleur, donc 4000 itérations pour un coloriage 4) ; l'estimation avait été faite sans tenir compte - entre autres choses - de la puissance optique réellement disponible. On peut désormais calculer correctement ce nombre, en supposant toujours une source optique d'un Watt. Le rapport de la BPO_i au nombre d'itérations minimum nécessaires pour réaliser le recuit sérieux (1000 mises à jour du champ entier) donne une véritable cadence de recuit quelque quatre fois moins importante que celle avancée (pour le voisinage 4). Il reste toutefois que cette cadence est *trois* ordres de grandeur en dessus de la cadence vidéo... Le *tab.VII.5* ci-dessous rend compte des performances finales du nouveau prototype.

Système de voisinage	Cadence maximale F_{clock} (MHz) pour $P_{tot}=1W$:	BPO_i (Mbits/s) :	BPG (Gbits/s) :	Recuits sérieux à la seconde :
SPIE600 (*)	($P_{tot}=100mW$)	21,3 bits/s	49 kbits/s	0,02
4 (PPOS ₄)	73,3	36,7	150	36700
8 (PPOS ₈)	66,8	16,7	137	16700
12 (PPOS ₁₂)	64,1	12,8	158	12800

Tab.VII.5 : Estimation des performances pour le nouveau prototype de PPOS (16x32 PEs) en technologie hybride CMOS-SEED et interconnexions holographiques. () Le prototype de PPOS non monolithique étudié au Chap.V et expérimenté au Chap.VI est présent pour comparaison (voisinage 4).*

Conclusion générale

Bien que le processeur optoélectronique présenté dans cette thèse se situe dans la lignée des travaux précédents effectués au laboratoire sur les "rétines artificielles" exploitant le parallélisme "optique" de l'image, il s'en écarte notamment par le fait que l'acquisition, le conditionnement et le pré-traitement du signal ne sont pas directement pris en charge par le processeur ; en effet, celui-ci est exclusivement dédié au problème de l'*estimation* des primitives de l'image, après "fusion" des données observés dans un modèle *a priori* de type probabiliste. Cette étape *d'optimisation* est "difficile" au sens algorithmique et constitue le vrai "noyau dur" des méthodes d'estimation bayésiennes, c'est pourquoi la quasi totalité des dispositifs de vision artificielle fonctionnels (aussi bien les circuits ASIC que les programmes informatiques) sont construits autour d'algorithmes *déterministes* qui ne donnent que des résultats sous-optimaux - en un temps raisonnable. Un des objectifs réalisés dans cette thèse a été de montrer que, moyennant l'utilisation de composants optoélectroniques dédiés, il était possible d'intégrer des méthodes *d'optimisation stochastiques* au sein d'une chaîne complète de traitement d'images, et cela sans compromettre la contrainte de *temps réel*.

Le *processeur parallèle optoélectronique stochastique* dédié à l'optimisation par recuit simulé (PPOS en abrégé) rend l'exploit possible grâce à l'introduction de *fonctions optiques* spécifiques (cf. schéma fig.0.1 en Introduction) : des *interconnexions optiques* (entrée et/ou sortie de données parallèles, échange d'information entre pixels) mais aussi et surtout *un générateur de nombres aléatoires optique* basé sur le phénomène de speckle laser.

Avec le premier prototype de PPOS à *interconnexions électriques* présenté au chapitre III, nous avons démontré le débruitage d'images binaires à des cadences supérieures à la centaine de clichés par seconde. Cependant, force est de constater que la qualité du traitement reste très médiocre ; or, cela tient moins à la qualité de l'optimisation qu'à l'extrême simplicité de ce premier prototype, incapable par exemple de représenter des variables continues et encore moins de traiter *plusieurs* champs couplés en même temps, pas plus enfin que de réaliser des voisinages d'interaction larges entre les variables (binaires). Malgré cela, les résultats ont été très encourageants (comportement adéquat par rapport aux simulations et cadence de traitement élevée), c'est pourquoi nous avons cherché à valider le prototype de façon plus probante (et spectaculaire) en mettant au point un algorithme de détection du mouvement "taillé sur mesure" pour le prototype. Il convient de dire ici que, malgré le caractère on ne peut plus simpliste de l'algorithme proposé à la fin du chapitre IV, celui-ci réussit des performances honorables dans une gamme de situations (variations d'éclairement, contraste, vitesse, etc..) au moins aussi large que celle dont font preuve des algorithmes certainement plus complexes implantés

sur des cartes PC et proposés sur le marché (celles-ci utilisent bien sûr de méthodes d'optimisation déterministes).

Au chapitre V nous avons étudié l'architecture du prototype de démonstration final ; dans celui-ci, le schéma d'interconnexion entre PEs (ou voisinage) est réalisé par des moyens optiques, grâce à une boucle de rétroaction non monolithique formée par un modulateur spatial de lumière et un hologramme de Dammann interchangeable. Le prototype final, testé au chapitre VII, est d'une complexité considérable car il intègre en même temps deux *fonctions optiques* différentes (générateur de nombres aléatoires optique et montage de convolution compact). Malgré un montage optomécanique non optimisé, nous voulons comme preuve du bon fonctionnement de chacune de ces fonctions le comportement satisfaisant du démonstrateur face au problème du débruitage d'images binaires et de la détection du mouvement (il est vrai que la nature même du traitement le rend relativement "robuste" face aux imperfections du système). Le générateur de nombres aléatoires optiques a été testé lors de travaux précédents (verre de spin), ainsi que pour le débruitage d'images binaires (chapitre III de cette thèse) ; en ce qui concerne les interconnexions optiques *inter-processeur*, le résultat le plus important a été de démontrer la possibilité de réaliser des schémas d'interconnexion plus ou moins complexes grâce à des éléments optiques bon marché. Nous souhaitons ainsi avoir contribué à prouver que l'introduction de fonctions optiques dans les systèmes de traitement de l'information est relativement facile et ne demande pas de nos jours d'un budget extraordinaire.

Perspectives.

En ce qui concerne l'encombrement et les performances, l'étude théorique menée au chapitre VII permet d'affirmer que l'utilisation d'une puce optoélectronique à entrées et sorties optiques rendrait le système à la fois compact (taille comparable à celle d'un processeur Pentium avec ses éléments de réfrigération - le diffuseur tournant du générateur de speckle pourrait prendre la place du ventilateur) et extrêmement rapide (milliers de recuits sérieux par seconde). En effet, la cadence de traitement est, dans le "pire" des cas (voisinage d'ordre 3), au moins 500 fois plus élevée que la cadence vidéo (*cf. tab.VII.5*), et cela indépendamment de la taille de l'image. Cette puissance de calcul peut être utilisée pour traiter plusieurs flux de données-images en même temps, ou, comme suggéré au Chap.VII, §3.2 (et à condition de trouver un algorithme de décomposition adéquat), pour traiter des images de taille considérable en utilisant des matrices de faible résolution.

Dans ce travail de thèse nous nous sommes restreint au cadre du traitement d'images, et nous avons pris comme exemple central le problème de la détection du mouvement ; il est cependant possible d'utiliser le PPOS dans un contexte plus général de traitement du signal, en particulier pour réaliser des réseaux de neurones récurrents stochastiques (ce sont les machines de Boltzmann exposés brièvement au chapitre III). Il faudrait alors

Conclusion générale

réaliser des schémas d'interconnexion plus complexes, non invariants par translation et variables dans le temps, en utilisant des éléments diffractifs reconfigurables.

Enfin, cette étude devrait clore à notre avis la phase amont de la recherche sur les processeurs parallèles optoélectroniques stochastiques. L'avenir (commercial?) de ces processeurs dédiés dépendra de l'attention que l'industrie voudra bien y prêter en vue d'ouvrir des marchés futurs.

ANNEXES

Annexe A :

Modulateur Spatial de Lumière

1. Rappel sur les cristaux liquides ferroélectriques

Certains matériaux appelés cristaux liquides présentent une *mésophase* entre une phase liquide (parfaitement isotrope) et une phase solide (fortement anisotrope) ; une certaine fluidité de la phase cristal liquide par rapport à la phase solide permet de modifier la position des molécules et donc de commander l'anisotropie du milieu. Lorsque la température augmente à partir de la phase solide, les molécules du cristal liquide gardent pourtant une organisation en couches et présentent une direction privilégiée, mais il n'y a plus d'ordre de position à l'intérieur des couches : c'est la phase *smectique*. A température un peu plus élevée, les molécules présentent toujours une direction privilégiée, mais il n'y a plus d'organisation en couches : c'est la phase *nématique*.

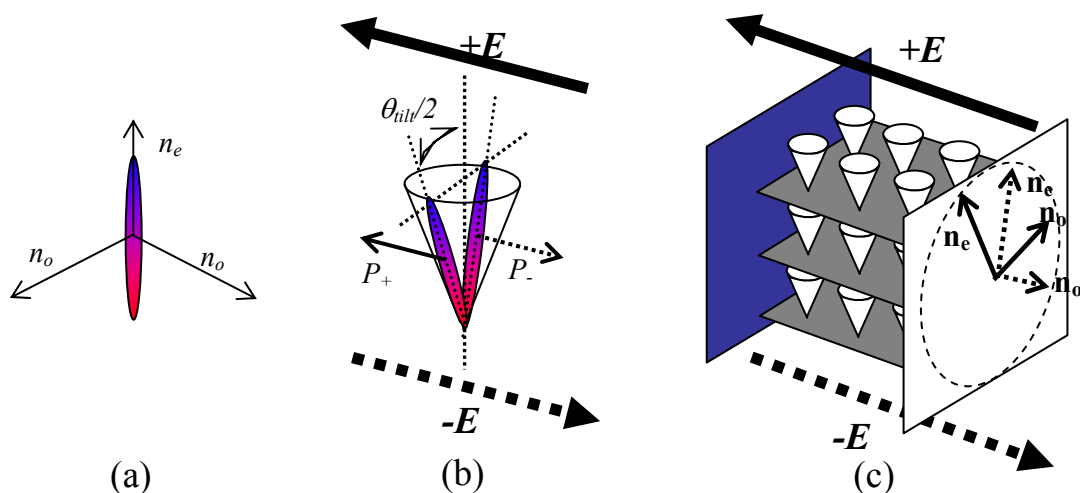


Fig.A.1 : (a) Les molécules du CLF sont longilignes : le matériau est biréfringent. (b) Le vecteur polarisation moléculaire a tendance à s'aligner avec le champ électrique externe, et la molécule tourne dans le cône smectique. (c) Organisation en couches smectiques du cristal liquide ferroélectrique.

Les cristaux liquides ferroélectriques sont des cristaux liquides en phase smectique C* (SmC^*) : les molécules, logilignes et chirales, sont *inclinaées* par rapport au plan des couches - la phase smectique A est caractérisée par une direction des molécules *orthogonale* aux couches. Chaque molécule possède un vecteur de polarisation perpendiculaire à son axe. Les molécules peuvent tourner autour d'un cône d'angle θ_{tilt} (voir *fig.A.1*). Le matériau présente macroscopiquement deux indices de réfraction différents. Si l'on applique un champ électrique externe, le vecteur polarisation des molécules tend à s'aligner avec le champ. Si on ne modifie pas la direction du champ mais juste son sens, les molécules s'orientent selon deux positions diamétralement opposés sur le cône. En créant des zones où le champ peut être contrôlé indépendamment (zone active des pixels), on peut construire un modulateur spatial de lumière.

Dans les modulateurs par réflexion, le cristal liquide est confiné entre une contre-électrode conductrice transparente et une électrode métallisée qui remplit le rôle de réflecteur optique. Pour plus de détails sur les cristaux liquides ferroélectriques (CLF), voir par exemple [Moigna97].

2. Caractérisation des SLM.

Les modulateur spatiaux de lumière (SLM) utilisés dans notre démonstrateur (Chap.V) sont fournis par Displaytech, (SLM-256-A, [Display]). Il s'agit de circuits CL/CI (cristaux liquides sur circuit intégré) à cristaux liquides ferroélectriques binaires. Ils fonctionnent en mode réflexion et les axes optiques sont disposés pour réaliser une modulation d'amplitude (voir *fig.A.2* ci-dessous).




Fig.A.2 : Axes géométriques et axes optiques du modulateur spatial de lumière. L'angle de tilt idéal vaut 45° pour une modulation d'amplitude. Le cube séparateur polarisant (CSP) joue le rôle de polariseur et d'analyseur (il bloque l'état de polarisation OFF).

2.1 Caractéristiques constructeur.

Géométrie :

- Taille de la matrice : 256x256 pixels (3.84 mm²)
- Taille du pixel : 14 μm²
- Facteur de remplissage : 87% (gap 1 μm)

Caractéristiques Electriques :

- CLF sur circuit intégré CMOS standard (5V).
- Puissance dissipée : 150mW à la cadence maximale.
- Temps de commutation optique : 250 μs (23°C, Vdd=5V).
- Fréquence maximale de mise à jour de la matrice entière : 2500Hz.

Caractéristiques Optiques :

- Modulateur d'amplitude : angle de *tilt* 45° ; axe rapide OFF sur la verticale (±2°), voir *fig.A.2*.
- Epaisseur quart d'onde pour la longueur d'onde 680 nm (la longueur d'onde nominale des diodes laser du démonstrateur est précisément de 680 nm).
- Puissance optique tolérée : >500 mW/cm².
- Contraste. Pour un modulateur en amplitude, le contraste donné par le constructeur est défini comme le rapport entre les intensités réfléchies dans les états passant (ON) et bloquant (OFF). Les paramètres approximatifs donnés par le constructeur sont : par imagerie : **25:1** ; de l'ordre 0 : **100:1**

Remarques :

1) **Problème de compensation des charges**. La mémorisation d'un état du CLF est effectuée de manière électrique, c'est à dire en maintenant la tension de commande aux bornes de la cellule. Cependant, si les charges s'accumulent aux bornes du CLF, celui-ci se verra dégradé par électrolyse. Il faut donc appliquer une tension inverse après chaque lecture optique afin de compenser l'accumulation de charges. Le circuit proposé par Displaytech possède une commande spéciale pour inverser l'image sur le modulateur ; cependant, ceci réduit la cadence de mise à jour utile à seulement **1250 Hz**. Une astuce permet cependant d'atteindre la cadence maximale pour le SLM-B (responsable du bouclage optoélectronique) : étant donné qu'un recuit entier s'effectue en 40ms, on garde en mémoire toute la suite d'images déroulée pendant la mise à jour du champ ; à la fin du recuit, pendant que l'on inverse l'image du SLM-A (responsable de l'introduction de l'image à recuire), on déroule sur le SLM-B la suite mémorisé en *inversant* chaque image (voir Chap.IV). Le temps de rafraîchissement revient alors à 400 μs (la centaine de μs caractérise le temps de commutation du CLF [Collin95]).

2) **Bande passante optique (BPO)** (*cf.* Chap.VII,§2). Le modulateur de lumière Displaytech est un composant CLF/CI ayant une bande passante optique maximale égale à $BPO = 256 \times 256 \times 2500 = 164 \text{ Mb/s}$.

3. Angle de tilt mesuré et contraste maximal

Nous avons procédé à une caractérisation plus précise du composant une fois intégré dans notre système optique. On a mesuré le *contraste par imagerie*, c'est à dire que l'on intègre dans la mesure de l'intensité la composante réfléchiée par la surface inactive entre pixels. Nous nous intéressons au contraste par imagerie et non au contraste dit *de l'ordre 0* puisque le but est d'utiliser des macropixels, incluant une zone inactive (voir Chap.VI).

3.1 Montage de mesure

On utilise lors de la mesure l'un ou l'autre des bras du démonstrateur final, en fonction du SLM testé (voir Chap.V,§2). Ainsi on pourra tenir compte dans les mesures de tout défaut "système". Le SLM est imagé sur une caméra CCD (*fig.A.3*) qui prend la place de la puce optoélectronique. On projette une figure en damier sur le SLM et l'on mesure à l'aide d'un logiciel de traitement d'images (*NIH*) la moyenne d'intensité sur les zones obscures et sur les zones claires (histogramme de l'image entière). La procédure est répétée pour divers angles du socle tournant du SLM.




Fig.A.3 : Le montage de mesure correspond au montage optique du démonstrateur final (bras A ou bras B sans hologramme, cf. Chap.V), à ceci près qu'une CCD remplace la puce SPIE600.

On s'est tout d'abord assuré de la linéarité de la CCD (et de la conversion analogique-digitale nécessaire pour le logiciel de traitement d'images, logiciel *Map92p* et *CCD Synapse*) au moyen d'un analyseur tournant (voir *fig.A.4* ci-contre). La *fig.A.5* donne l'intensité (unités arbitraires) mesuré à l'état ON et à l'état OFF pour divers angles du socle du SLM (par rapport au cube séparateur de polarisation). L'angle d'origine n'est pas connu au début de la mesure. Par la suite, le modèle nous permet de lui donner une valeur ($\theta_0 \approx 50^\circ$).




Fig.A.4: Linéarité de la CCD. L'intensité mesuré suit très précisément la loi en \sin^2 .




Fig.A.5 : Mesure de l'intensité pour état passant et bloquant (ON et OFF) du SLM. Les courbes en continu représentent le "fit" par le modèle : $I=A.\sin^2(\varphi+w.\theta)+B$.

A partir de l'intensité ON et OFF on peut calculer le contraste par imagerie $C=I_{ON}/I_{OFF}$. La fig.A.6 donne le contraste en fonction de l'angle que font les axes optiques du SLM par rapport aux axes du cube. Le contraste maximal vaut $C=19 \pm 7$.




Fig.A.6 : Mesure du contraste (par imagerie). La courbe en continu représente l'ajustement par le modèle (§3).

3.2 Interprétation des résultats.

On se propose ici de déduire à partir des mesures l'angle de tilt réel du modulateur. Soit E_1 le champ attaquant le SLM. Pour simplifier on prendra $\theta_0=0$ (le cube séparateur polarisant – CSP - est aligné avec les axes du SLM et le champ est polarisé selon Ox). L'analyseur de sortie (l'autre axe du cube) est dirigé selon Oy (voir fig.A.7 ci-dessous).

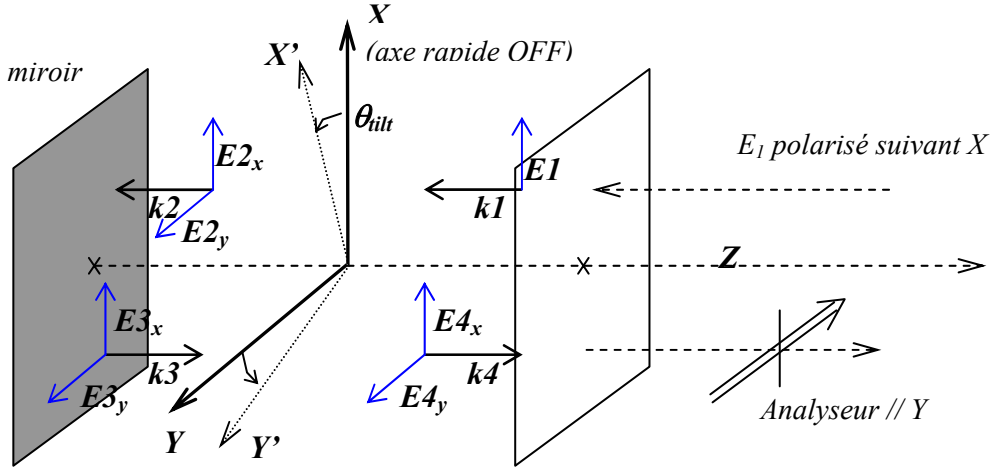


Fig.A.7 : L'axe rapide et l'axe lent du cristal liquide tournent d'un angle θ_{tilt} par application d'un champ électrique perpendiculaire au plan des couches.

Dans ces conditions on a :

$$\vec{E}_1 = E_1 \begin{pmatrix} 1 \\ 0 \end{pmatrix}_{(X,Y)}, \text{ dans le repère initial (état OFF) des axes optiques (X,Y).}$$

Si θ_{tilt} est l'angle de *tilt*, alors dans le nouveau repère (X',Y') des axes optiques à l'état *ON*, le champ E_1 s'écrit :

$$\vec{E}_1 = E_1 \begin{pmatrix} \cos(\theta_{tilt}) & -\sin(\theta_{tilt}) \\ \sin(\theta_{tilt}) & \cos(\theta_{tilt}) \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = E_1 \begin{pmatrix} \cos(\theta_{tilt}) \\ \sin(\theta_{tilt}) \end{pmatrix}_{(X',Y')}$$

Après un premier passage dans le cristal, le champ devient :

$$\vec{E}_2 = E_1 \begin{pmatrix} \cos(\theta_{tilt}) \\ \sin(\theta_{tilt}) \cdot e^{i\varphi} \end{pmatrix}_{(X',Y')}, \text{ (l'axe X' est l'axe rapide, la composante du champ sur Y' retarde de } \varphi \text{).}$$

Après réflexion sur la face métallisée, le champ devient :

$$\vec{E}_3 = \begin{pmatrix} e^{i\pi} & 0 \\ 0 & e^{i\pi} \end{pmatrix} \vec{E}_2 = -\vec{E}_2 = \begin{pmatrix} -\cos(\theta_{tilt}) \\ -\sin(\theta_{tilt}) \cdot e^{i\varphi} \end{pmatrix}_{(X',Y')} \text{ (} E_3 \text{ se propage selon Oz).}$$

Enfin, après une deuxième traversée dans le milieu anisotrope le retard s'accumule sur la composante $E_{4y'}$ du champ :

$$\vec{E}_4 = \begin{pmatrix} -\cos(\theta_{\text{tilt}}) \\ -\sin(\theta_{\text{tilt}}).e^{i2\varphi} \end{pmatrix}_{(X',Y')}, \text{ et l'on revient sur repère initial (i.e. celui du cube}$$

polariseur/analyseur), alors le champ sortant s'écrit :

$$\vec{E}_4 = \begin{pmatrix} \cos(\theta_{\text{tilt}}) & \sin(\theta_{\text{tilt}}) \\ -\sin(\theta_{\text{tilt}}) & \cos(\theta_{\text{tilt}}) \end{pmatrix} \begin{pmatrix} -\cos(\theta_{\text{tilt}}) \\ -\sin(\theta_{\text{tilt}}).e^{i2\varphi} \end{pmatrix} = - \begin{pmatrix} \cos^2(\theta_{\text{tilt}}).[1 - e^{i2\varphi}] + e^{i2\varphi} \\ \sin(\theta_{\text{tilt}}).\cos(\theta_{\text{tilt}})[-1 + e^{i2\varphi}] \end{pmatrix}_{(X,Y)}$$

L'intensité mesuré étant proportionnelle à $I_{\text{mesuré}} \propto \langle |E_{4Y}|^2 \rangle = \frac{1}{2} \{E_{4Y} . E_{4Y}^* \}$,

on a finalement $I_{\text{mesuré}} = I_m . \sin^2(2.\theta_{\text{tilt}}) . \sin^2(\varphi)$, avec $I_m = \text{cte}$. Si le cube séparateur de polarisation (PCB) n'est pas aligné avec les axes du cristal, mais fait un angle θ avec ceux-ci, alors on a respectivement :

$$\begin{aligned} I_{OFF} &= I_m . \sin^2(2.\theta) . \sin^2(\varphi) + I_c \text{ et} \\ I_{ON} &= I_m . \sin^2(2.(\theta + \theta_{\text{tilt}})) . \sin^2(\varphi) + I_c \end{aligned}$$

(une composante continue I_c vient se rajouter à l'intensité mesuré, provenant de la lumière réfléchiée dans les zones inactives du SLM). D'où le contraste :

$$C(\theta) = \frac{\sin^2(2\theta + 2.\theta_{\text{tilt}}) + a}{\sin^2(2\theta) + a}, \text{ (avec } a = \frac{I_c}{I_m \sin^2(\varphi)} \ll 1 \text{)}.$$

Celui-ci est maximal pour $\theta \approx k\pi/2$. Notre montage est bien configuré pour la modulation d'amplitude -les axes du cube sont parallèles aux axes du SLM. La modulation d'amplitude serait idéale pour $\theta_{\text{tilt}} = \pi/4$ et $\varphi = \pi/2$ (lame quart d'onde pour un passage, demi-onde après deux passages dans le cristal). Les courbes du modèle I_{ON} et I_{OFF} sont représentées par des traits continus dans la *fig.A6*. Les résultats du *fit* confirment le modèle, mais l'on trouve un angle de tilt $\theta_{\text{tilt}} = 34,4^\circ$ résultat assez différent de la valeur donnée par le constructeur ($\theta_{\text{tilt}} = 45^\circ$). Le contraste maximal vaut $C = 19 \pm 7$, (voir *fig.A.6*). Le constructeur donne $C=25$, valeur qui tombe dans l'intervalle d'erreur de nos mesures. Cette valeur va nos permettre d'établir le bilan optique de démonstrateur (Chap.V,§5).

Annexe B :

Hologrammes synthétiques pour la convolution optique.

1. Introduction

Dans la version du prototype avec boucle de rétroaction optoélectronique (Chap.V), les interconnexions entre PEs sont réalisées de façon optique par convolution du champ d'étiquettes courant codé en mode double-voie sur le SLM-B (fig.B.1).




Fig B.1 : Rétroaction optoélectronique et réponse impulsionnelle de l'hologramme pour l'interconnexion optique dans l'exemple d'un voisinage d'ordre 2.

La réponse impulsionnelle de l'élément responsable de la convolution se limite donc à un ensemble fini de pics (fig.B.2). On a choisi de réaliser cette opération au moyen d'un hologramme synthétique (CGH -Computer Generated Hologram en anglais) de type réseau de Damman [Damman77]. Dans tous les cas, l'ordre 0 et les autres ordres de l'hologramme qui tombent en dehors du voisinage choisi doivent être aussi atténués que possible. Les ordres qui nous intéressent doivent en plus cumuler le maximum d'intensité lumineuse sans qu'il y ait de variation significative d'intensité entre les différents pics – une dispersion maximale de l'ordre de 5% est tolérable, car elle correspond à la variation inévitable de l'éclairement des photodétecteurs par translation (Chap.V,§2.3). Par contre, la phase relative entre les différents ordres n'est pas importante. Pour éviter les pertes, on a opté pour des hologrammes de phase. Par des méthodes de photogravure sur de la résine photosensible, on pouvait aisément réaliser dans le laboratoire des composants à deux niveaux de phase. Ces hologrammes binaires de phase sont réalisés par périodisation d'un motif élémentaire carré ou cellule : ce sont des réseaux de Damman à deux niveaux de phase. Leur réponse impulsionnelle est donc le produit de la



Fig.B.2 : Réponse impulsionnelle du CGH (voisinage d'ordre 2) - image réelle CCD.

transformée de Fourier de la cellule élémentaire (enveloppe) par un peigne de Dirac bidimensionnel. Le motif est une matrice de pixels carrés à valeurs dans l'ensemble $\{1, e^{i\varphi}\}$, ou φ est la différence de phase entre les deux niveaux. Ainsi, plus le motif aura de pixels et plus on aura de degrés de liberté qui vont permettre de

mieux ajuster l'enveloppe pour annuler efficacement certains ordres et en faire ressortir convenablement les autres [Dames91]. La recherche exhaustive de la meilleure solution pour la cellule élémentaire – une fois que l'on s'est fixé l'objectif d'une certaine réponse impulsionnelle - s'avère impossible dès que la taille du motif devient conséquente. Ceci semble inévitable si la disposition et l'intensité des spots que l'on cherche à reproduire sont un peu particulières (voisinage du troisième ordre, voire déjà pour le deuxième ordre). On a donc opté pour des algorithmes d'optimisation stochastique, plus précisément on a employé la technique du recuit simulé. Remarquons enfin que l'efficacité d'un tel réseau peut être bien supérieure à celle d'un réseau de Dammann bidimensionnel obtenu par produit de deux réseaux perpendiculaires unidimensionnels (technique classique pour éviter la charge de calcul). En effet, dans notre approche 2-D on dispose d'un nombre beaucoup plus élevé de degrés de liberté.

2. Modélisation.

L'hologramme synthétique est placé entre le SLM et la puce dans un montage de type Van-Der-Lugt. (voir fig.B.3 ci-dessous).




Fig.B.3 : Hologramme synthétique. Les axes X et Y correspondent aux directions de périodicité du motif de l'hologramme dans le cas du voisinage 4.

Soit $h(x,y)$ la transmittance de l'hologramme. Alors on peut écrire (on ne s'occupe pas pour l'instant de l'étendue finie de l'hologramme) :

$$h(x,y) = C(x,y) * \sum_{k,l} \delta(x-k\Lambda, y-l\Lambda)$$

où $C(x,y)$ est la transmittance du motif, et Λ la période du réseau. Si le motif est carré et comporte $N \times N$ pixels (il n'est pas obligatoire que le motif soit carré, mais la symétrie du voisinage en fait un choix raisonnable) alors on peut écrire aussi :

$$C(x,y) = \sum_{n,m=(0,0)}^{N-1,N-1} C_{nm} \delta(x - \frac{\Lambda}{N}n, y - \frac{\Lambda}{N}m) * \text{rect}\left(\frac{xN}{\Lambda}, \frac{yN}{\Lambda}\right)$$

Dans la formule, les coefficients C_{nm} sont à valeurs dans $\{1, e^{i\phi}\}$. La transformée de Fourier de la transmittance de l'hologramme (ou réponse impulsionnelle) s'écrit alors :

$$TF\{h\}(\mu, \nu) = TF\{C\} \times \frac{1}{\Lambda^2} \sum_{k,l} \delta\left(\mu - \frac{k}{\Lambda}, \nu - \frac{l}{\Lambda}\right)$$

La TF de la cellule $C(x,y)$ étant :

$$TF\{C\}(\mu, \nu) = \frac{\Lambda^2}{N^2} \sum_{n,m} C_{nm} \sin_c\left(\frac{\Lambda}{N}\mu\right) \sin_c\left(\frac{\Lambda}{N}\nu\right) e^{\frac{2i\pi\Lambda}{N}(n\eta + m\nu)}$$

On obtient finalement :

$$TF\{h\}(\mu, \nu) = \frac{1}{N^2} \sum_{k,l} \sum_{n,m}^{N-1,N-1} C_{nm} e^{\frac{2i\pi\Lambda}{N}(n\eta + m\nu)} \sin_c\left(\frac{k}{N}\right) \sin_c\left(\frac{l}{N}\right) \delta\left(\mu - \frac{k}{\Lambda}, \nu - \frac{l}{\Lambda}\right)$$

L'amplitude de l'ordre (k,l) vaut alors :

$$a_{k,l} = \frac{1}{N^2} \sin_c\left(\frac{k}{N}\right) \sin_c\left(\frac{l}{N}\right) \sum_{n,m=(0,0)}^{(N-1,N-1)} C_{nm} e^{\frac{2i\pi}{N}(kn+lm)}$$

On reconnaît dans la formule de l'amplitude la Transformée de Fourier Discrète (TFD) de la cellule élémentaire :

$$TFD\{C\}(k,l) = \sum_{n,m=(0,0)}^{(N-1,N-1)} C_{nm} e^{\frac{2i\pi}{N}(kn+lm)}, \text{ ce qui va permettre d'accélérer}$$

l'optimisation lors du calcul de la fonction de coût.

Soit $I^o = (I^o_{kl})$ la matrice des intensités des spots recherché (normalisée), et I_{kl} l'intensité du pic reconstruit dans l'ordre (k,l) :

$$I_{kl} = |a_{kl}|^2$$

On peut définir alors la fonction de coût à minimiser (ou *erreur de reconstruction*) par la formule :

$$E(C/I) = \sum_{k,l} |I^o_{kl} - I_{kl}|$$

Il suffit de calculer cette somme pour les ordres non nuls de la matrice I^o . En effet, en sachant que l'énergie de l'onde sortante est finie (normalisé ici et égale à la somme de

l'intensité dans tous les ordres), si l'on maximise l'énergie sur les ordres intéressants on aura automatiquement une minimisation de l'énergie ailleurs.

La fonction de coût est une fonction à N^2 variables binaires (les coefficients de la cellule élémentaire). Avant de lancer le calcul de l'optimisation par recuit simulé, il vaut mieux trouver une borne supérieure pour le nombre de pixels de la cellule, ce qui évitera une perte de temps de calcul importante. Ainsi, on a les considérations suivantes :

- La résolution finie de l'imprimante laser. Le masque pour l'hologramme est obtenu par réduction photographique d'une impression laser (HP LaserJet 4/4M PlusPS). Le facteur de réduction du banc est de 20 et la résolution de l'imprimante est de $R=600$ dpi (dots per inch), ce qui correspond à un diamètre de $42 \mu\text{m}$ pour chaque point d'encre sur le papier. Le pas du réseau étant $\Lambda=256\mu\text{m}$ (voir §2.1), on a alors la relation : $a' = 20.a = 20 \cdot \frac{\Lambda}{N} \geq R$, où a est la taille d'un pixel de la cellule et a' celle d'un point dans le papier. Ceci conduit à une borne supérieure pour le côté de la cellule : $N \leq 122$.
- Par ailleurs, il faut que le pas du réseau soit beaucoup plus grand que la longueur d'onde utile ($\lambda=680$ nm), (sinon il faudrait utiliser une théorie électromagnétique plus exacte). Cette condition s'écrit : $a = \frac{\Lambda}{N} \gg \lambda$, ce qui conduit à $N \ll 376$. Mais la résolution de l'imprimante est donc le premier facteur limitant.
- Enfin, on a déterminé (de façon heuristique) la taille minimale de la cellule au delà de laquelle la variation relative du coût semble négligeable. Il serait alors inutile de perdre du temps pour des cellules plus grandes (le temps de calcul varie comme N^2). Il s'avère que pour tous les réseaux étudiés, un minimum profond de la fonction de coût est atteint pour des tailles de l'ordre de $N=30$. Nous avons pris $N=32$ pour accélérer le calcul de la FFT (méthode radix-2).

Quelques commentaires avant de présenter les résultats de la synthèse :

- L'optimisation peut se faire en contraignant seulement la valeur des spots sur la moitié de la matrice des intensités recherchés. En effet, on montre facilement que puisque les variables C_{nm} sont binaires (hologramme à deux niveaux de phase), la réponse impulsionnelle du CGH est symétrique par rapport à l'origine.
- Remarquons aussi qu'une condition nécessaire pour que l'ordre 0 soit nul est qu'il y ait autant d'éléments à 1 dans la cellule élémentaire qu'il y en a d'éléments à +1 (le retard de phase ϕ est égal à π). Cette condition doit en principe être retrouvée lors du recuit simulé (par la contrainte de nullité de l'ordre 0). Mais si l'on veut privilégier plus particulièrement cette condition, on peut introduire une troisième contrainte –pas seulement dans la fonction d'énergie mais dans l'algorithme

d'optimisation lui-même- pour s'assurer de cette 'symétrie' des valeurs. Alors, *quel qu'il soit* le résultat de l'optimisation, l'ordre 0 sera (théoriquement) toujours nul.

- Dans le cas qui nous intéresse, i.e. la réalisation d'interconnexions optiques aux plus proches voisins, il est très important que l'intensité des spots soit la plus uniforme possible ; l'efficacité n'est pas nécessairement une priorité (i.e. il y a suffisamment d'énergie et l'on peut perdre un peu sur les ordres en dehors du voisinage –très peu sur chacun d'eux mais une quantité non négligeable au total). On peut se préoccuper davantage de l'uniformité en rajoutant un terme de régularisation à la fonction de coût :

$$E(C/I) = \sum_{(k,l) \in V} I_{kl} + \lambda \frac{1}{N^2} \sum_{(k,l) \in V} (I_{kl} - I_{moy})^2$$

Le premier terme correspond à l'efficacité de l'hologramme dans les ordres non nuls du voisinage. Le deuxième terme est la variance de l'intensité sur l'ensemble de ces ordres (I_{moy} représente l'intensité moyenne sur les spots non nuls). Le terme λ permet de contrôler l'importance relative de chaque contrainte. On a retenu ce type de fonction de coût pour l'optimisation stochastique (dans nos calculs on a toujours $\lambda \gg 1$ et typiquement $\lambda = 32$).

3. Résultats de la synthèse.

On présente maintenant les résultats théoriques pour divers hologrammes synthétiques (voisinage 4, 8, 12 et noyau de B-codage). L'optimisation pour chacun d'eux prend à peu près une dizaine de minutes pour des cellules 32x32 sur un ordinateur Pentium 120Mhz. Cependant, pour ne pas avoir à refaire des essais trop nombreux, on a préféré d'emblée une décroissance lente de la température et on a fixé les variables du recuit pour qu'un bon équilibre thermodynamique des variables soit assuré à chaque palier (*cf.* Chap.II). Le calcul prend alors jusqu'à 2 heures sur le même ordinateur, mais on est sûr de bien distinguer le problème d'optimisation du choix de la fonction à optimiser. La *fig.B.4* représente la variation de la fonction de coût avec la température pendant le recuit pour la synthèse du voisinage d'ordre 3 (12 voisins -*cf.* §3.2). On s'est assuré que les températures initiales et finales se trouvent bien de part et d'autre de la température critique. Les valeurs typiques pour le recuit sont : $T_i = 0,3$, $T_f = 0,003$, $r = 0,9$, $nscan = 10$, ce qui représente quelque 440 itérations, et un temps de calcul d'à peu près 1h 30mn.


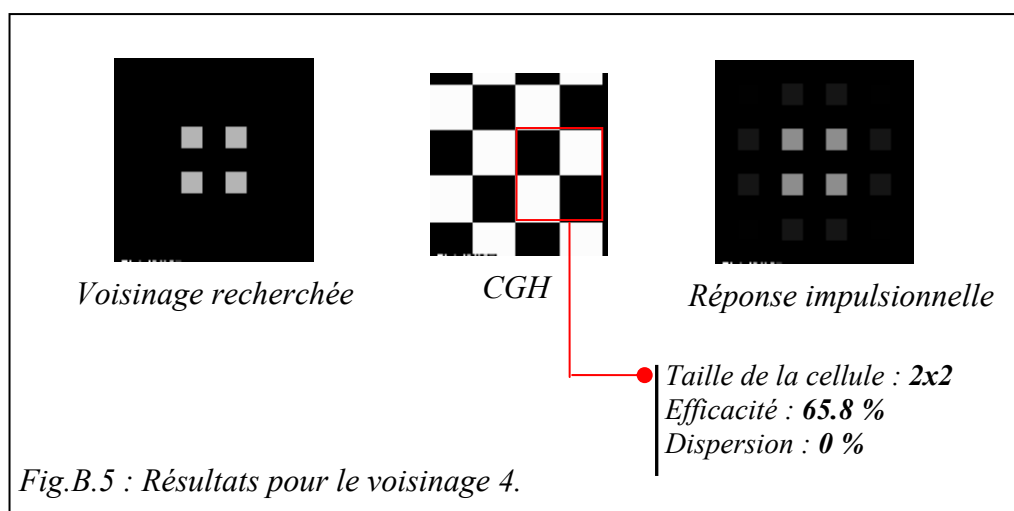



Fig.B.4 : Décroissance du coût avec la température pendant le recuit.

3.1 Voisinage d'ordre 1 (aux 4 plus proches voisins).

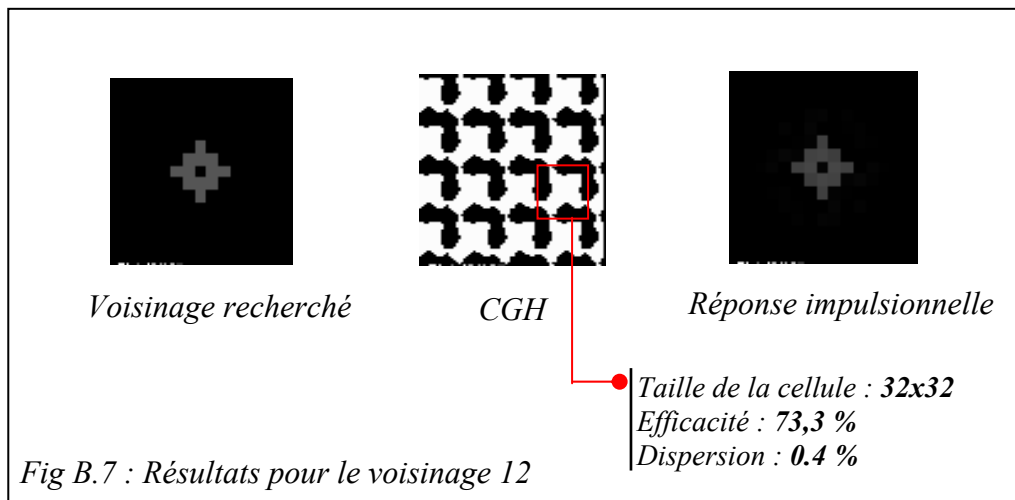
La fig.B.5 représente la matrice I^0 , le réseau de Dammann et la réponse impulsionnelle correspondante pour le voisinage de premier ordre (4 voisins). L'efficacité dans chacun des 4 pics qui nous intéressent est égale à 16,42 %. Ceci signifie que 34% de l'énergie est perdue dans les ordres supérieurs (l'efficacité de l'ordre suivant le plus intense vaut 1,8%) . Il s'agit cependant de la meilleure solution que l'on peut obtenir avec un hologramme à deux niveaux de phase. Remarquons par ailleurs que ce réseau est aussi un réseau de Dammann obtenu par superposition de deux réseaux unidimensionnels très simples donnant l'ordre 1 et -1 avec une efficacité de 40,5 % ($40,5^2 = 16,42$).



3.2 Voisinage d'ordre 2 (aux 8 plus proches voisins).



3.3 Voisinage d'ordre 3 (aux 12 plus proches voisins).

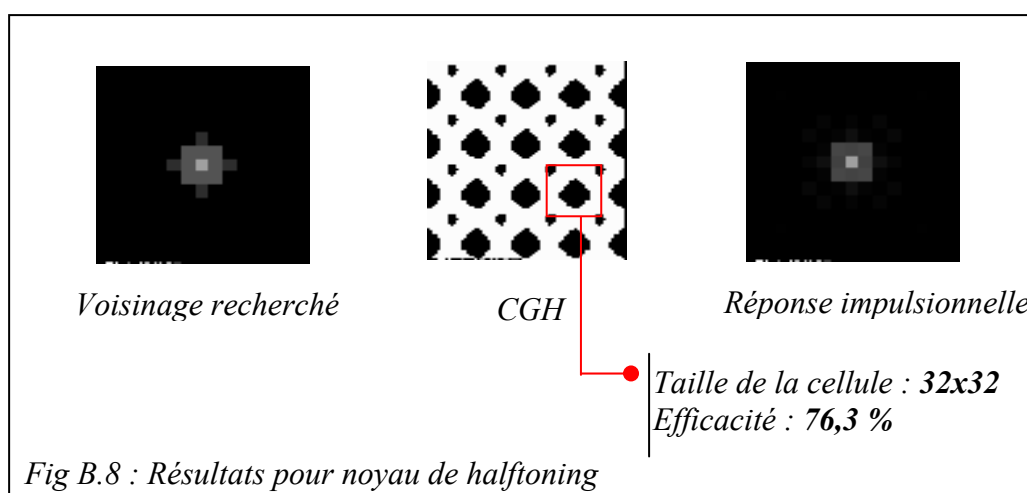


3.4 Noyau de convolution pour le B-codage d'images.

On a aussi synthétisé un hologramme pour réaliser le noyau de convolution nécessaire à l'opération de B-codage (voir Chap. VI, §2.3). Dans ce cas, l'intensité des spots n'est pas uniforme, et l'ordre 0 n'est pas nul. En effet, le noyau de convolution (normalisé) s'écrit :

$$K = \frac{1}{21} \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 2 & 1 & 0 \\ 1 & 2 & 5 & 2 & 1 \\ 0 & 1 & 2 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

La contrainte d'uniformité est donc relâchée. On n'impose pas par ailleurs la nullité de l'ordre 0, ce qui se traduit par un nombre non égal des quantités binaires (un fond continu apparaît dans l'hologramme, responsable de l'ordre 0). On aurait pu synthétiser l'hologramme en imposant un ordre 0 nul, et ensuite jouer sur l'épaisseur de la résine (*cf.* §4) pour faire ressortir l'ordre 0. On a opté pour la première méthode puisque lors des tests sur le premier hologramme on a fixé l'épaisseur de la résine pour annuler l'ordre 0 le plus efficacement possible (*fig.*B.8).



4. Réalisation des réseaux.

La réalisation du réseau de phase se fait par gravure du motif sur de la résine photosensible. On enduit un substrat d'une couche de photorésine, puis on isole certaines parties au moyen d'un masque et on éclaire avec des UV. Le développement enlève ensuite les parties non isolées.

4.1 Réalisation du masque.

Le masque est une photographie sur plaque de verre du motif du réseau. Il doit avoir la même taille que le réseau lui même puisque lors de l'insolation aux UV il sera directement en contact avec le substrat. Ce masque est réalisé par photoréduction à partir d'un transparent issu d'une imprimante laser. Le rapport de réduction du banc optique est de $R=20$ et la résolution de l'imprimante laser est de 600dpi, soit 23,2 points par millimètre.

L'hologramme est placé devant la lentille L2 de focale f_2 . Si l'on considère l'approximation de Fresnel, alors dans le plan de la puce la fréquence (μ, ν) correspond aux coordonnées $(x/\lambda.f_2, y/\lambda.f_2)$. L'ordre (k, l) a donc comme coordonnées en fréquences spatiales :

$$\frac{x_k}{\lambda.f_2} = \frac{k}{\Lambda}, \quad \frac{y_l}{\lambda.f_2} = \frac{l}{\Lambda}$$

Puisque les photodétecteurs se trouvent espacés tous les $l_p = 216 \mu\text{m}$ (fig.B.9 - voir aussi fig.V.3 au Chap.V), alors le pas Λ du réseau s'obtient par la formule :

$$\Lambda = \frac{\lambda.f_2}{l_p}$$

dans le cas du 8-voisinage et du 12-voisinage. Il est égal à $256 \mu\text{m}$ pour le montage retenu et pour la longueur d'onde de la diode laser. Pour le 4-voisinage, on prendra plutôt :

$$\Lambda = \frac{\lambda.f_2}{\sqrt{2}.l_p}$$

et on tournera le réseau de 45° . En effet, pour ce réseau la solution est connue (voir §3.1) : il s'agit d'un réseau carré en damier, et la synthèse du CGH sera plus efficace si l'on s'intéresse aux ordres $(1,1)$, $(1,-1)$, $(-1,-1)$, $(-1,1)$. Autrement, le rendu par pixelisation des cases carrés du damier serait imparfait car elles auraient une disposition diagonale.

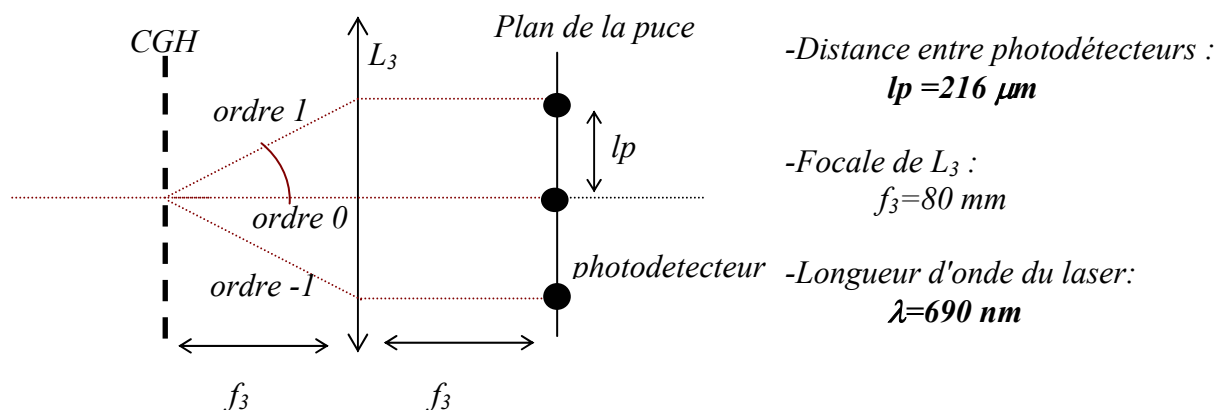


Fig.B.9 : paramètres optiques pour le calcul du pas du réseau.

Remarque. Pour des cellules élémentaires de côté $N < 17$, on aboutit à une taille du pixel égale à : $a = \frac{\Lambda}{N} = \frac{256 \mu m}{17} > 15 \mu m$,

ce qui veut dire que l'on pourrait utiliser un de nos SLM binaires (taille du pixel : $15 \mu m$) pour construire des éléments diffractifs reconfigurables à la place des hologrammes en résine - à condition d'utiliser un montage en modulation de phase pour les SLM. Cependant, l'ordre 0 ne serait pas efficacement annulé, puisque comme on peut le voir dans l'Annexe A, notre SLM permet un déphasage maximal de 67° . En plus, si l'on ne modifie pas le montage proposé au Chap.V, la taille du SLM étant petite ($L = 3.84 \text{ mm}$), on peut s'attendre à un phénomène de vignettage (la taille d'un spot sera égale à $2\lambda f/L = 28 \mu m$ et puisque l'image géométrique du macropixel sur la puce fait $G.3.bs = 64 \mu m$, l'image réelle de celui-ci fera $64 + 28 = 92 \mu m$: une tache trois fois plus grande que celle d'un photodétecteur seul).

4.2 Contrôle de l'épaisseur.

4.2.1 Le problème expérimental.

Pour avoir exactement une différence de phase de π entre les zones éclairées de la résine et les zones occultées par le masque, il faut pouvoir contrôler précisément l'épaisseur de la couche enduite. En effet, pour annuler l'ordre 0, il faut que l'épaisseur de la résine soit exactement égale à :

$$e = \frac{\lambda}{2(n-1)}, \text{ où } n \text{ est l'indice de la résine. Celui-ci dépend de}$$

la dilution et de la longueur d'onde utile. A partir des caractéristiques techniques de la résine utilisée (SHIPLEY S1813) d'indice $n = 1.62$ à $\lambda = 690 \text{ nm}$, on obtient pour l'épaisseur voulue la valeur $e = 0,55 \mu m$. On a procédé par essais successifs (en changeant soit la dilution de la résine, soit la vitesse de la tournette utilisée pour l'enduction par centrifugation) en cherchant à obtenir un ordre 0 aussi faible que possible dans le cas du 4-voisinage.

Par ailleurs, le dépôt de résine doit être uniforme sur toute la surface ; il faut pour cela que le substrat soit le plus propre possible. On travaille pour cela en salle grise, avec gants et combinaison. Néanmoins, un gradient d'épaisseur est inévitable depuis le centre de la plaque vers les bords - à cause de la centrifugation. Pour cela, on s'est limité à un seul réseau gravé par plaque, situé au centre de celle-ci.

4.2.2 Erreur en épaisseur.

Une mauvaise épaisseur de la résine se traduit par une perte d'efficacité et un ordre 0 non nul. Plus précisément, soit $\Delta\varphi$ l'écart en phase par rapport au déphasage parfait de π . Alors l'amplitude de l'ordre (k,l) est, à un facteur de phase près, égale à :

$$a'_{kl} = \cos\left(\frac{\Delta\varphi}{2}\right)a_{kl} - \sin\left(\frac{\Delta\varphi}{2}\right)\delta_{kl},$$

où a_{kl} est l'amplitude calculée au §A.2 et δ_{kl} est le symbole de Kronecker. L'intensité de l'ordre (k,l) est proportionnelle à :

$$I'_{kl} = \cos^2\left(\frac{\Delta\varphi}{2}\right)I_{kl} + \delta_{kl} \left\{ \sin(\Delta\varphi) \operatorname{Re}(a_{00}) + \sin^2\left(\frac{\Delta\varphi}{2}\right) \right\}$$

Si l'hologramme était optimisé pour annuler l'ordre 0, alors $I_{00}=0$ et on a alors :

$$I'_{kl} = \cos^2\left(\frac{\Delta\varphi}{2}\right)I_{kl} + \delta_{kl} \sin^2\left(\frac{\Delta\varphi}{2}\right)$$

Ainsi, l'efficacité définie par : $\eta' = \cos^2\left(\frac{\Delta\varphi}{2}\right)\eta$, devient $\eta = \sum_{(k,l) \in V} I_{kl}$ et l'ordre 0 réapparaît. L'efficacité de l'ordre 0 vaut :

$$\eta'_{00} = \sin^2\left(\frac{\Delta\varphi}{2}\right)$$

4.2.3 Influence de l'ordre 0 sur l'algorithme de recuit simulé.

Si l'ordre 0 n'est pas correctement annulé, alors s'ajoute à la *force locale* de mise à jour (voir Chap.IV,§6.2.3) un terme supplémentaire qui ne peut pas être représenté simplement par une modification de la fonction d'énergie globale : il s'agit d'une force qui n'est pas issue d'un potentiel, mais dépend de la valeur de l'étiquette locale. Le terme supplémentaire agit donc comme une force non conservative de type frottement visqueux. Intuitivement, on peut supposer que cette force tend à "bloquer" l'état du site à sa valeur courante, surtout pour des faibles températures. Le recuit simulé est perturbé et on peut imaginer que le système sera plus facilement bloqué dans des minimums locaux de la fonction de coût si la décroissance de la température est trop abrupte.

Sans aller très loin dans l'étude, on a simulé le comportement de l'algorithme (restauration d'images binaires) pour une contribution de l'ordre 0 à la force locale au moins aussi importante que celle des autres ordres (ce qui de toutes façons est loin d'être le cas, voir §5). Le test d'équilibre thermodynamique (voir Chap.III,§6.2.2) montre un léger écart par rapport à la pente théorique (voir *fig.B.11*), ce qui signifie que l'équilibre n'est pas bien réalisé (l'écart de 6% par rapport à la pente théorique n'est cependant pas interprété de façon quantitative quand à l'efficacité du recuit). Les résultats ne semblent pourtant pas trop affectés, et le minimum de l'énergie atteint reste profond (*fig.B.10*).



Image originale (50x50)
(bruit de canal 28%)

Paramètres du recuit :

$$T_i=5 \quad T_f=0,1 \quad r=0,95 \quad \text{et} \quad nscan=5$$

Paramètres du modèle de débruitage :

$$\beta_0=1,95 \quad ; \quad \beta_s=1 \quad ; \quad \text{voisinage d'ordre 2}$$




Fig.B.10 : Influence de l'ordre 0 dans la qualité du recuit. Le graphique représente le minimum de l'énergie atteint en faisant varier le poids relatif de l'ordre 0 (par rapport à β_s).

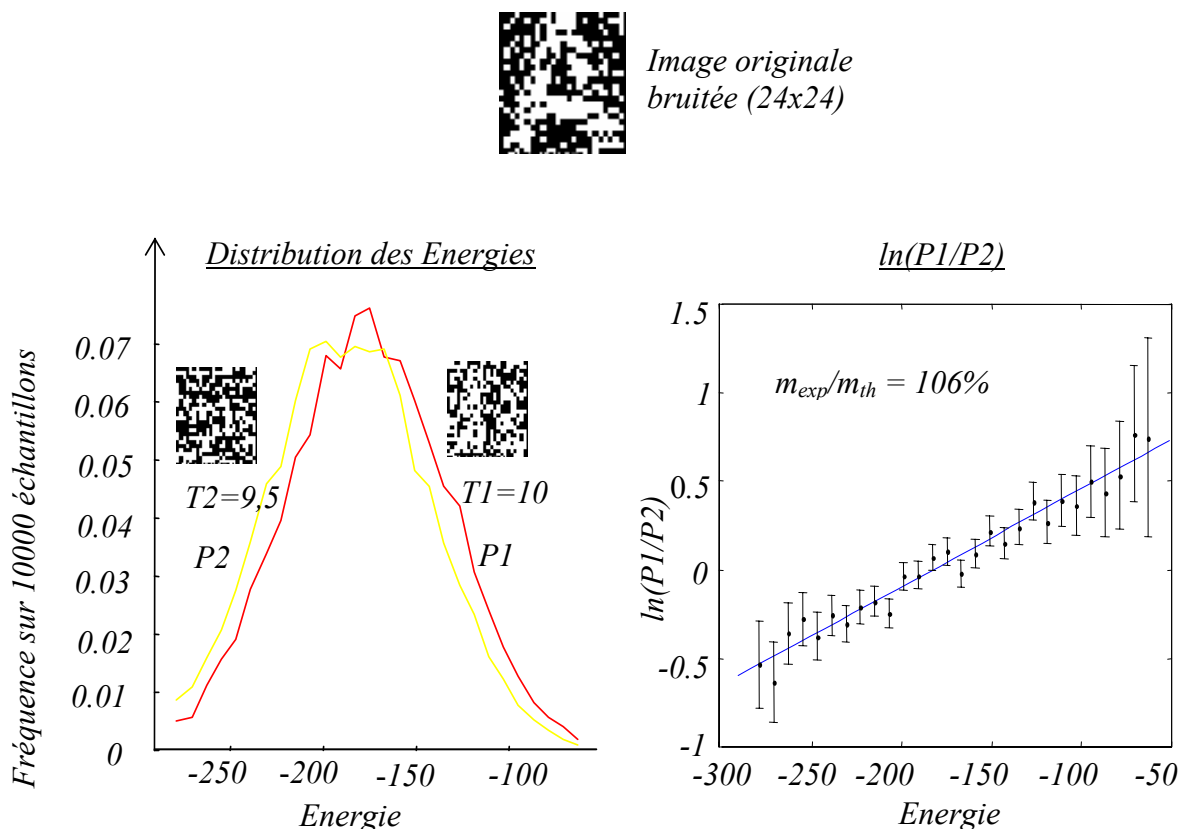


Fig.B.11 : Test de l'équilibre thermodynamique pour un ordre 0 aussi important que les ordres utiles ($\beta_{\text{ordre}0} = \beta_S = 1$).
 La force locale vaut $F(s) = \beta_S \Sigma(2e(r)-1) + \beta_O \cdot O(s) + \beta_{\text{ordre}0} \cdot (2e(s)-1) + h$.

5. Résultats expérimentaux.

Les mesures ont été faites avec une caméra CCD et un logiciel de traitement d'images. Les résultats sont issus d'une moyenne sur l'étendue spatiale de l'image du macropixel, et d'une moyenne sur les ordres équivalents. On a évité de travailler en dehors de la dynamique de la CCD ; pour cela il a fallu atténuer avec un filtre polariseur le faisceau direct (référence), et l'enlever pour réaliser les mesures quand l'hologramme est à sa place. L'image provient des macropixels 3x3 du SLM (voir fig.B.12), ce qui a l'avantage de fournir une mesure directement transposable dans le montage final. Le calcul de l'efficacité de l'hologramme doit donc prendre en compte le contraste du SLM, égal à $C=20:1$ (voir Annexe B). On a essayé toujours de travailler avec l'image centrée sur le système optique, pour éviter de prendre en compte des imperfections de l'éclairage.

5.1 Exemple de mesure : voisinage d'ordre 1.




Fig.B.12 : (a) Image CCD de deux macropixels responsables du codage en double voie d'une sortie de PE (en temps normal ils ne sont pas actifs en même temps). (b) Résultat de la convolution optique (voisinage d'ordre 1). Comparer avec Fig.B.1.

A partir de ces données, on peut calculer l'efficacité de l'hologramme. Soit $I_p = (226 \pm 8)$ l'intensité du macropixel et $I_f = (9 \pm 2)$ l'intensité du fond du SLM avant la mise en place de l'hologramme. Soient α_0, α_1 et α_2 , les efficacités dans l'ordre 0, les spots du voisinage et les ordres supérieurs non négligeables respectivement (voir fig.B.13).

Tout d'abord on vérifie bien que $I_p/I_f = (25 \pm 3)$ tombe dans l'intervalle d'erreur du contraste maximal du modulateur $C=(20\pm 7)$ (voir Annexe A).

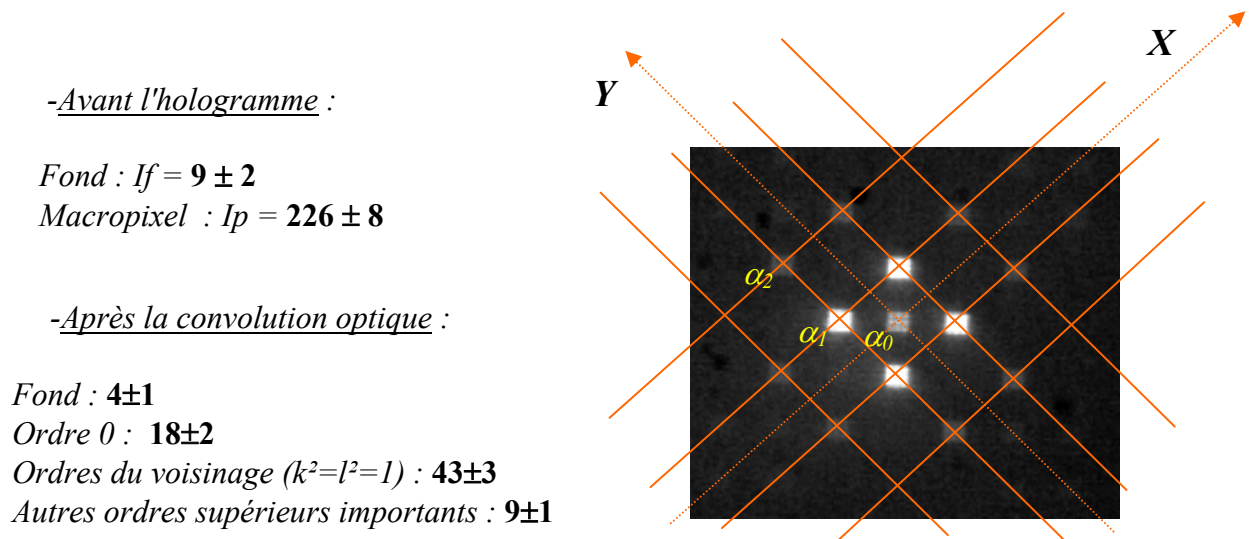


Fig.B.13 : mesure de l'intensité des ordres de diffraction.

On a alors le système linéaire suivant, en se limitant aux 3 ordres les plus intenses (les autres ne se distinguent pas du fond si l'on tient compte de leur intervalle d'erreur) :

$$\left\{ \begin{array}{l} \alpha_0 I_p + 4\alpha_1 I_f + 8\alpha_2 I_f = (18 \pm 2) \\ \alpha_1 I_p + 3\alpha_1 I_f + 8\alpha_2 I_f = (43 \pm 3) \\ \alpha_2 I_p + 4\alpha_1 I_f + 7\alpha_2 I_f = (9 \pm 1) \end{array} \right. \quad \text{On trouve donc : } \left\{ \begin{array}{l} \alpha_0 = (4,9 \pm 0,1) \% \\ \alpha_1 = (16,7 \pm 0,7) \% \\ \alpha_2 = (1 \pm 0,4) \% \end{array} \right.$$

La mesure de efficacité sur l'ordre utile (α_1) correspond très bien à la prédiction théorique (16,4%). Par contre, l'épaisseur de la résine n'est pas parfaite pour annuler l'ordre 0 ; il reste toutefois 4 fois moins intense que l'ordre utile. En reprenant les calculs pour chacun des 4 ordres formant le voisinage utile, on trouve finalement un écart de 0,6% autour de la valeur moyenne ($16,5 \pm 0,6$ %). Cette dispersion ne peut être due qu'à des défauts de dépôt de résine ou d'éclairement du montage de mesure (théoriquement elle est nulle).

On a procédé de la même façon pour les CGH correspondant aux voisinages 8 et 12 (on n'a pas eu le temps de caractériser le CGH pour le noyau de B-codage). Tous les résultats sont collectés dans le *tab.B.1*. ci-dessous :

Voisinage	Efficacité dans l'ordre utile (%)	Efficacité totale utile expérimentale et théorique (%)	Efficacité de l'ordre 0
4	$16,5 \pm 0,6$	66 ± 2 / 65,8	$4,9 \pm 0,1$ %
8	$9,1 \pm 0,9$	73 ± 7 / 69,2	2,4 %
12	$7,5 \pm 0,8$	90 ± 10 / 73,3	2 %

Tab.B.1 : efficacités de diffraction pour les réseau de Dammann responsables du voisinage par convolution optique.

Ces résultats seront repris au Chap.V pour fixer la puissance source du démonstrateur, et au Chap.VII pour analyser les performances théoriques de nouveaux prototypes.

Annexe C :

Description des séquences de mouvement

1. Introduction

Nous présentons ici quelques séquences (réelles et synthétiques) sur lesquelles nous avons pu tester l'algorithme proposé au Chap.IV, §6. Toutes les séquences sont constitués d'images à niveaux de gris discrets (8 bits). Les séquences synthétiques ont été générées sur Matlab ; les séquences réelles ont été acquises grâce à une caméra CCD de vidéoconférence Quickcam™ reliée à un PC de bureau par port parallèle.

Les calculs ont été réalisés sur un ordinateur PC Pentium 120MHz ; pour chaque séquence d'images, quatre résultats sont présentés (voir fig.C.1) dans l'ordre :

- deux séquences correspondant à des étapes de calcul intermédiaires, à savoir la carte de *changements temporels* (CCT) et le *champ binaire XOR* résultant de l'opération logique itérative : $XOR(t)=[XOR(t-1) \text{ xor } CCT(t)]$.
- deux séquences de détection finales (MB) correspondant respectivement au modèle de *Dumontier-Caplier* et à notre *modèle simplifié discret*.

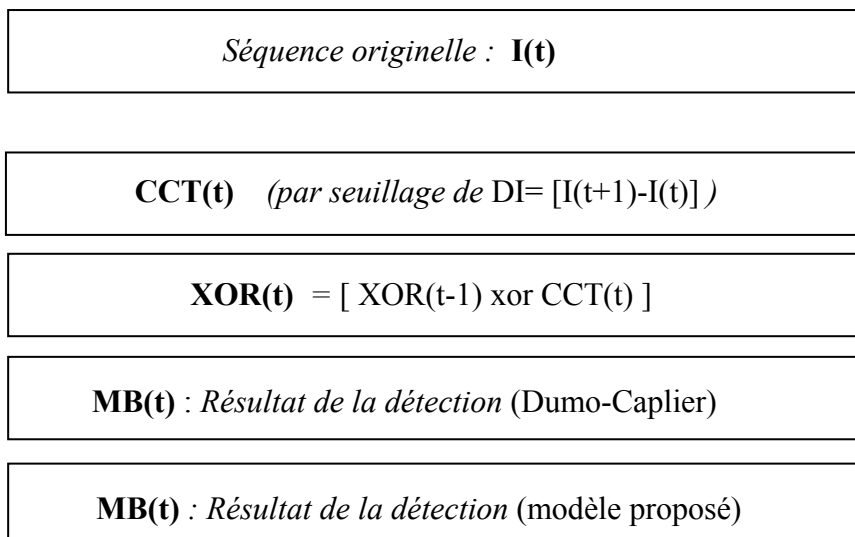


Fig.C.1 : Présentation type des résultats.

2. Séquences Synthétiques.

2.1 Séquence *Contraste_1*.

Paramètres :

- Fond : taille : 24x64 / niveau de gris : 180.
- Objet : taille : 8x16 / niveau de gris : 220.
- Bruit : bruit gaussien de variance $\sigma = 10$.
- Vitesse objet : 3 pixels/image vers la droite.
- Temps de calcul : Dumontier-Caplier : 2s/im (6 itérations) ;
Modèle proposé : 30s/im (93 itérations).

Extrait de la séquence, en prenant une image sur 4 :

Séquence Contraste_1



CCT



XOR



Modèle Dumontier



Modèle proposé



2.2 Séquence *Contraste_2* :

Les caractéristiques de la séquence sont les mêmes que pour *Contraste_1*, mais le contraste est légèrement inférieur (le niveau moyen du fond est 180 et celui de l'objet 200).

Extrait de la séquence, en prenant une image sur 4 :

Séquence Contraste_2



CCT



XOR



Modèle Dumontier



Modèle proposé




2.3 Séquence *Taille_1*

Paramètres :

- Fond : taille : 40x55 / niveau de gris : 180.
- Objet : taille : 8x8 / niveau de gris : 220.
- Bruit : bruit gaussien de variance $\sigma=10$.
- Vitesse objet : en diagonal à raison de $V=(v_x,v_y)=(3,2)$ pixels/image.
- Temps de calcul : Dumontier-Caplier : 3s/im (6 itérations)
Modèle proposé : 30s/im (70 itérations).

Extrait de la séquence, en prenant une image sur 4 :

Séquence Taille_1



CCT



XOR



Modèle Dumontier



Modèle proposé



2.4 Séquence *Taille_2* :

Paramètres :


- Fond : taille : 50x75 / niveau de gris : 180.
- Objet : taille : 10x20 / niveau de gris : 220.
- Bruit : bruit gaussien de variance $\sigma=10$.
- Vitesse objet : en diagonal à raison de $V=(v_x,v_y)=(3,2)$ pixels/image.
- Temps de calcul : Dumontier-Caplier : 4s/im (6 itérations).
Modèle proposé : 40s/im (93 itérations).

Extrait de la séquence, en prenant une image sur 4 :

Séquence Taille_2



CCT



XOR



Modèle Dumontier



Modèle proposé

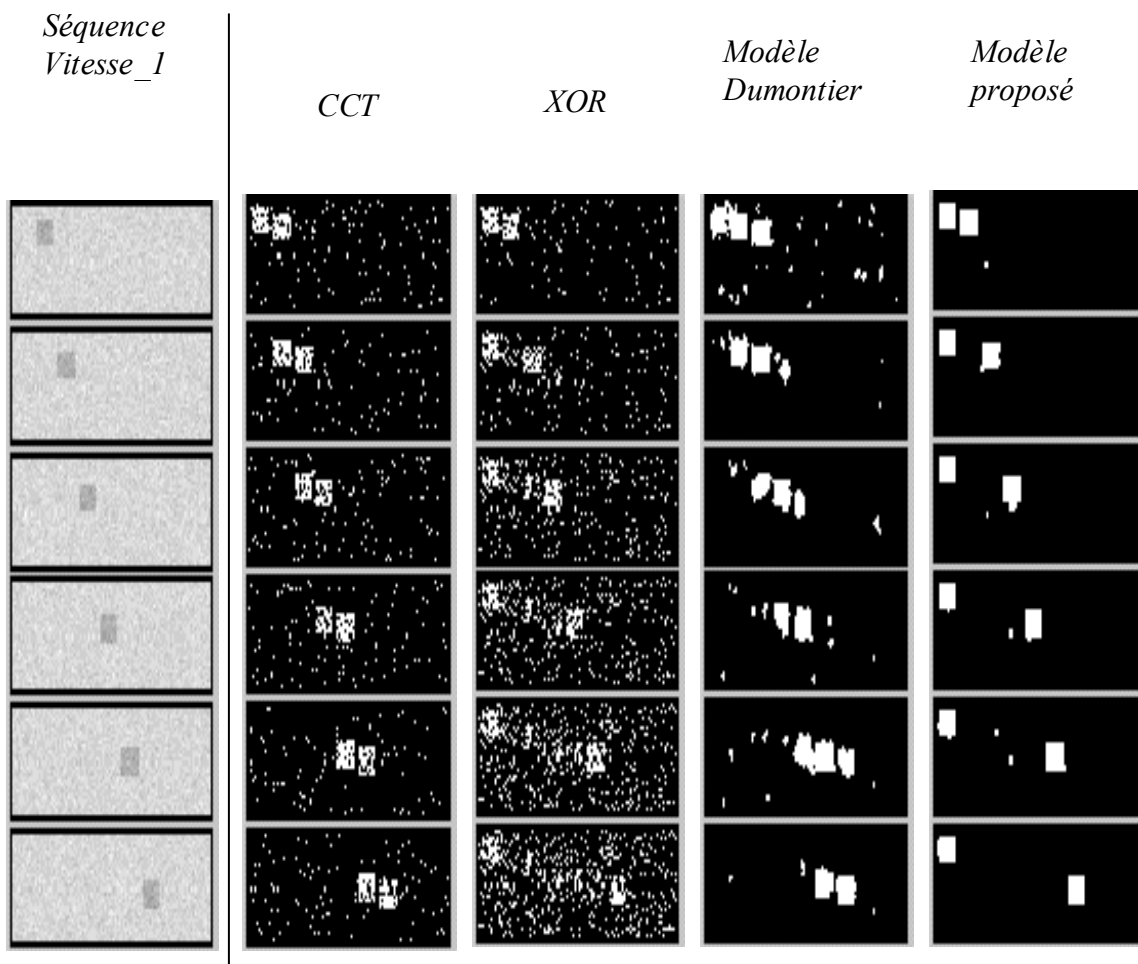


2.5 Séquence *Vitesse* :

Paramètres :

- Fond : taille : 140x32 / niveau de gris : 220.
- Objet : taille : 12x8 / niveau de gris : 180.
- Bruit : bruit gaussien de variance $\sigma=10$.
- Vitesse objet : en diagonal à raison de $V=(v_x,v_y)=(15,2)$ pixels/image.
- Temps de calcul : Dumontier-Caplier : 4,4s/im (6 itérations).
Modèle proposé : 42s/im (93 itérations).

Extrait de la séquence, en prenant une image sur 4 :




2.6 Séquence *Disque*

Paramètres :


- Fond : taille : 50x75 / niveau de gris : 220.
- Objet : disque de rayon 18 pixels / niveau de gris : 180.
- Bruit : bruit gaussien de variance $\sigma=10$.
- Vitesse objet : en diagonal, à raison de $V=(v_x, v_y)=(3,2)$ pixels/image.
- Temps de calcul : Dumontier-Caplier : 4s/im (6 itérations).
Modèle proposé : 37s/im (92 itérations).

Extrait de la séquence, en prenant une image sur 4 :

Séquence Disque_1



CCT



XOR



Modèle Dumontier



Modèle proposé



2.7 Séquence Croisement :


Il s'agit d'une séquence synthétique essayé dans la thèse de A.Caplier pour tester l'algorithme simplifié de Dumontier-Caplier.

Paramètres :

- Fond : taille : 140x50 / niveau de gris : 180.
- Objets : rectangle : 32x16, niveau de gris : 160
carré : 16x16, niveau de gris : 30.
- Bruit : bruit gaussien de variance $\sigma = 10$.
- Vitesse objet : rectangle : 1pixels/image vers la droite
carré : 1 pixels/image vers la gauche.
- Temps de calcul : Modèle Dumontier-Caplier : 7s/im (5 itérations, voisinage 8) ;
Modèle proposé : 59s/im (90 itérations, voisinage 4).

Extrait de la séquence, en prenant une image sur 5 :

Séquence Croisement (bruit gaussien $\sigma = 10$).



CCT (seuil $\theta=25$; bruit de canal faible $\varepsilon \approx 2\%$)



XOR



Modèle Dumontier



Modèle proposé



3. Séquences réelles


3.1 Séquence *Piétons*.

Paramètres :

- Fond : taille : 66x45/ niveau de gris ≈ 140 .
- Objet : piéton $\approx 20 \times 10$ / niveau de gris ≈ 220 .
- Bruit : ?
- Vitesse objet : entre 2 et 4 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 7s/im (5 itérations, voisinage 8).
Modèle proposé : 25s/im (40 itérations, voisinage 4).

Extrait de la séquence, en prenant une image sur 5 :

Séquence Piétons



CCT



Méthode XOR



Modèle Dumontier



Modèle proposé




3.2 Séquence *Couloir*

Paramètres :

- Fond : taille 24x24 / niveau de gris non uniforme (50-100)
- Objet : passant 6x20 / non uniforme.
- Bruit : ?
- Vitesse objet : entre 1 à 3 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 2s/im (5 itérations, voisinage 8).
Modèle proposé : 17s/im (40 itérations, voisinage 4).

Extrait de la séquence en prenant une image toutes les 3 :

Séquence Couloir.



CCT




XOR



Modèle Dumontier



Modèle proposé




3.3 Séquence *Automobile_1*

Paramètres :

- Fond : taille 98x69 / niveau de gris ≈ 140 .
- Objet : voiture $\approx 60 \times 25$ / niveau de gris ≈ 220 .
- Bruit : ?
- Vitesse objet : ≈ 8 à 10 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 6,4s/im (5 itérations, voisinage 8).
Modèle proposé : 94s/im (68 itérations, voisinage 4).

Extrait de la séquence en prenant une image toutes les 3 :

Séquence Automobile_1



CCT



Méthode XOR



Modèle Dumontier



Modèle proposé




3.4 Séquence *Automobile_1* bruitée.

Paramètres :


Extrait de la séquence en prenant une image toutes les 3 :

- Fond : taille 98x69 / niveau de gris ≈ 140 .
- Objet : voiture $\approx 60 \times 25$ / niveau de gris ≈ 220 .
- Bruit : rajout de bruit gaussien $\sigma=25$.
- Vitesse objet : ≈ 8 à 10 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 6,4s/im (5 itérations, voisinage 8).
Modèle proposé : 94s/im (68 itérations, voisinage 4).


Séquence Automobile_1 bruitée (bruit gaussien $\sigma=25$)



CCT (fond ≈ 140 , voiture ≈ 220 et $\sigma=25$ donc bruit de canal après seuillage: $\varepsilon=8\%$)



XOR



Modèle Dumontier



Modèle proposé

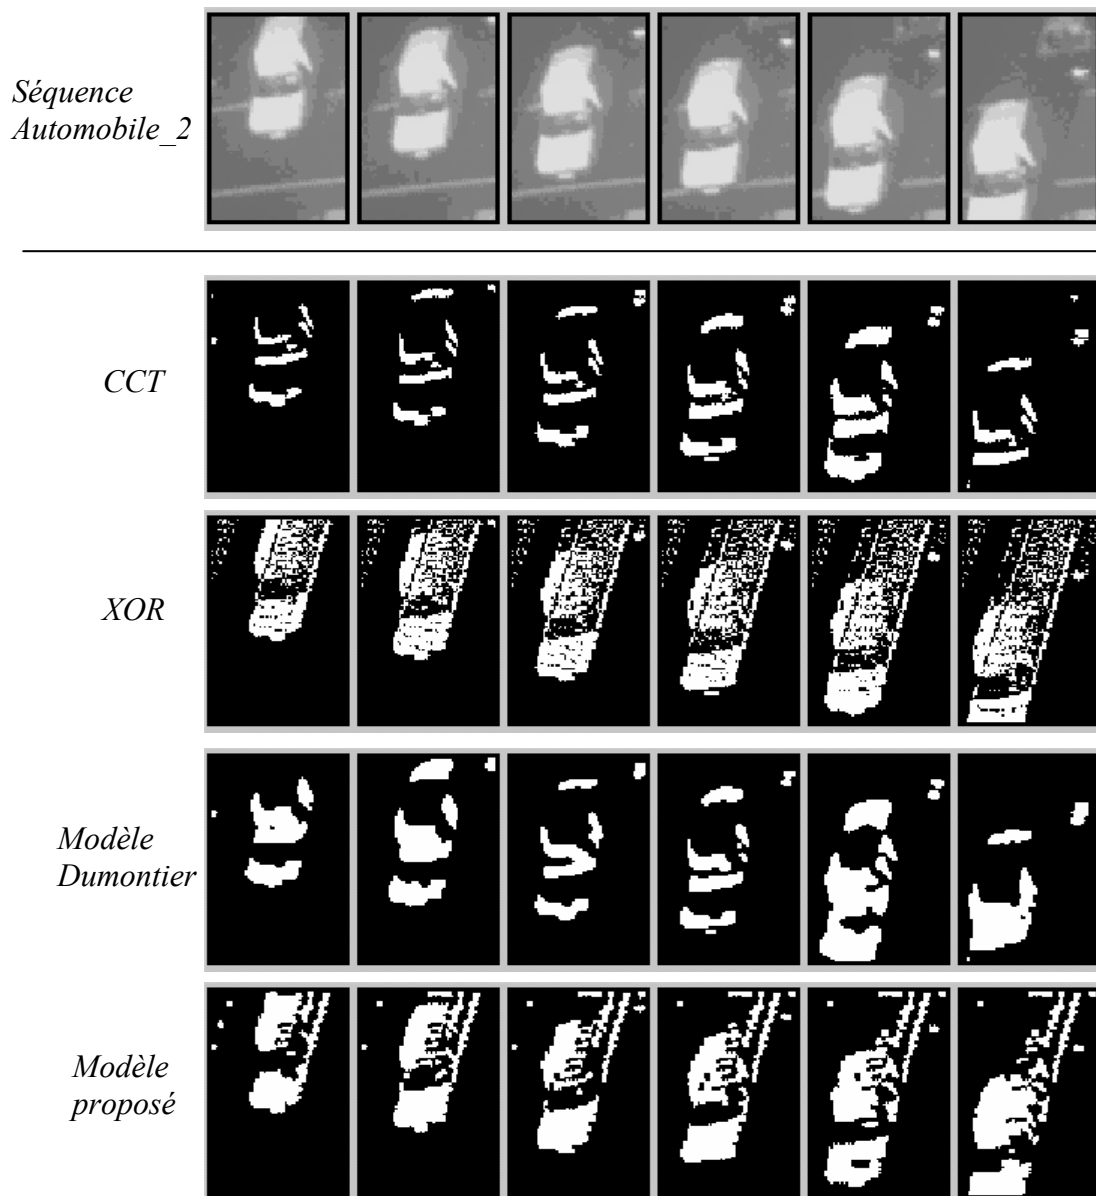


3.5 Séquence *Automobile_2*

Paramètres :

- Fond : taille 64x105 / niveau de gris ≈ 140 .
- Objet : voiture $\approx 32 \times 50$ / niveau de gris ≈ 220 .
- Bruit : ?
- Vitesse objet : ≈ 7 à 9 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 3,9s/im (5 itérations, voisinage 8).
Modèle proposé : 94s/im (69 itérations, voisinage 4).

Extrait de la séquence en prenant une image toutes les 2 :



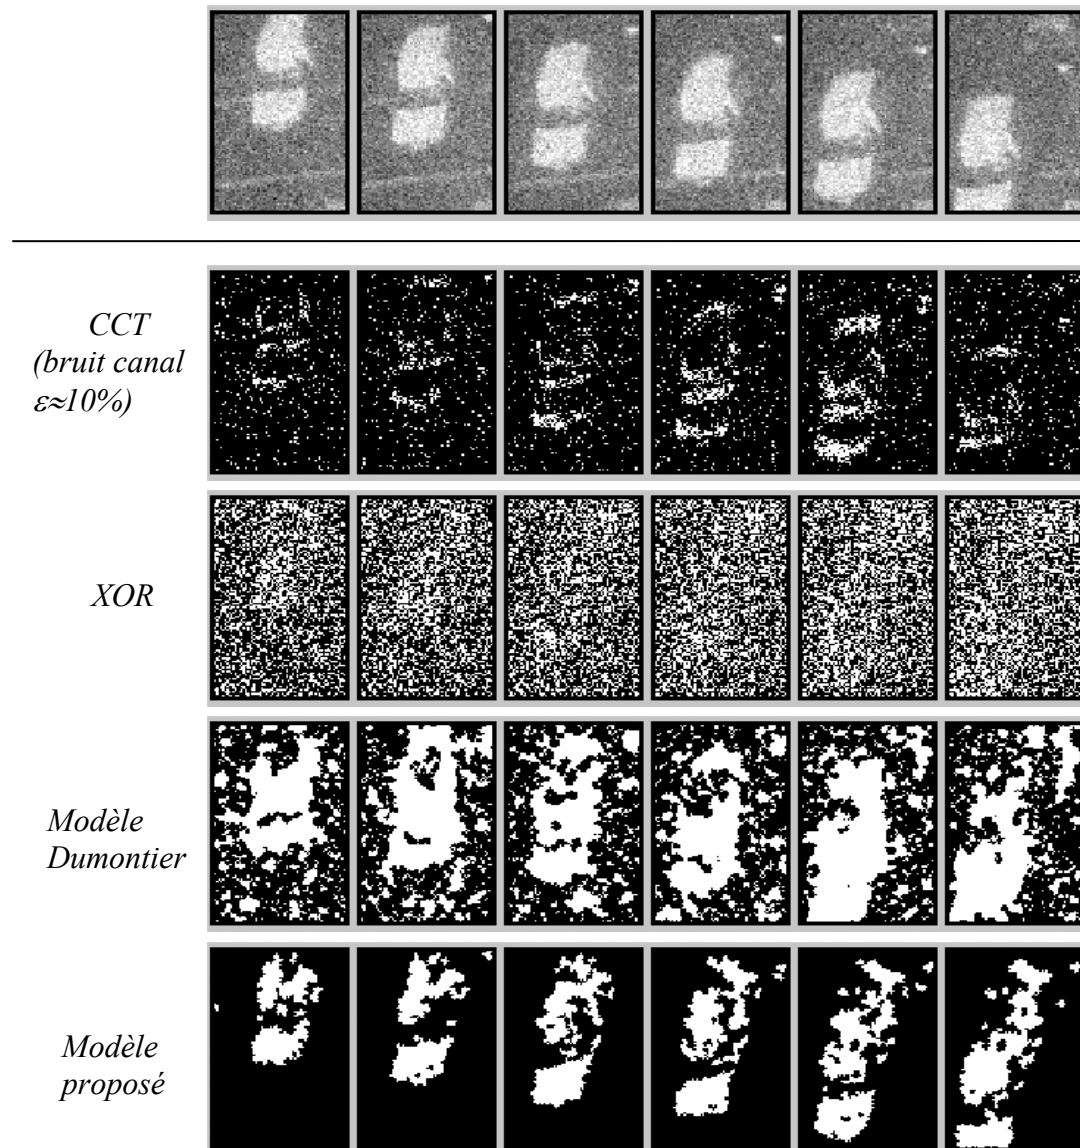
3.6 Séquence *Automobile_2* bruitée.

Paramètres :

- Fond : taille 64x105 / niveau de gris ≈ 140 .
- Objet : voiture 32x50 / niveau de gris ≈ 220 .
- Bruit : rajout de bruit gaussien $\sigma=25$.
- Vitesse objet : ≈ 7 à 9 pixels/image (voir CCT).
- Temps de calcul :
Dumontier-Caplier : 6,4s/im (5 itérations, voisinage 8).
Modèle proposé : 94s/im (68 itérations, voisinage 4).

Extrait de la séquence en prenant une image toutes les 2 :

Séquence Automobile_2 bruitée (bruit gaussien $\sigma=25$)



Annexe D :

Interface informatique

1. Introduction

Le démonstrateur comporte une partie optique et une partie électronique distinctes. Un ordinateur de type PC Pentium 100MHz commande la partie électronique de l'expérience. Les expériences pour lesquelles a été écrit un code informatique sont : (a) simulation du modèle d'Ising, (b) débruitage d'images et (c) détection du mouvement.

Le système électronique comporte trois cartes d'entrée-sortie commerciales et trois cartes-interface réalisées au laboratoire (une pour le contrôle de la puce - JC.Rodier -, une autre pour le contrôle des SLMs de Displaytech sans passer par le Driver Displaytech SliM-II - A.Villing - et une autre encore pour le contrôle de la puissance du laser de speckle - Rodier/Lalanne). Voici un descriptif des trois cartes commerciales (2 cartes *Intelligent Instrumentation* et une carte de *National Instruments*) et de leur fonction dans l'expérience (voir fig.V.24) :

- ☞ Carte **digitale** 20048W-1 (*Int.Inst.*) pour le contrôle du flux de données de la puce :
 - 3 ports 8 bits (ports #0, 1 et 2) pour les données (spins et interactions).
 - 1 port 8 bits (#3) pour le signal d'Horloge (Port_Horloge).
 - 1 port 8 bits (#4) pour les commandes (Port_Fonctions).
- ☞ Carte **Analogique/Digitale** 20428-W1 de *Int.Inst.* pour le contrôle du speckle, ainsi que (éventuellement) d'autres grandeurs analogiques de contrôle de la puce (f_{pol} pour les interactions électriques et h_{pol} pour le champ externe⁸⁷) ainsi que les commandes digitales de la carte. Le port de sortie A00 est réservé au contrôle du générateur de speckle.
- ☞ Une carte **digitale** National Instruments DIO-32HS pour *le bus de données parallèle* (32 bits) pour les SLM, à travers la carte dessinée par A.Villing. Par contre, les signaux de commande de cette carte proviennent de signaux digitaux fournis à travers la carte commerciale A/D 20428W1.

⁸⁷ Remarque : h_{pol} ne fonctionne que si f_{pol} est sous tension (problème de polarisation des transistors), c'est pourquoi on ne peut pas estimer la matrice des températures locales que à partir de quantités discrètes pour la force, et non pas en utilisant la contribution (en principe continue) du champ externe h (cf. Chap.VI.1.3).

2. Jeu d'instructions sous plate-forme MATLAB.

Nous présentons ici une liste descriptive des fonctions que l'on peut utiliser désormais sous environnement MATLAB pour commander l'expérience. Les fonctions ont été testées (compilés et exécutés) sous MATLAB version 5.2.0. L'ordinateur hôte est un PC Pentium 100MHz, le temps moyen d'exécution rapporté est calculé grâce aux instructions *tic* et *toc* de Matlab. Ces fonctions peuvent être utilisées comme n'importe quelle autre fonction *built-in* de matlab (ce qui veut dire qu'elles peuvent être utilisées dans des M-files matlab ou appelés tout simplement dans le prompt >> de l'interpréteur MATLAB).

Ce jeu d'instructions correspond à des fonctions en C compilés sous matlab (grâce à la commande *mex*) pour en faire des fichier DLL (MEX-files) dont le fonctionnement se veut totalement transparent à l'utilisateur. On ne peut donc pas les éditer comme des M-file, mais on peut regarder – et modifier éventuellement - le fichier source (de même nom et finissant par XXX.c). Des explications pour re-compiler les routines sous matlab s'y trouvent en en-tête des programme en C.

2.1 Fonctions d'initialisation.

La plupart des instructions de ce jeu ne peuvent fonctionner sans initialisation préalable des cartes qui contrôlent le flux de données entre la puce, l'ordinateur et les SLMs. C'est pourquoi, avant tout appel à ces fonctions, il faut faire (et cela une seule fois) : **Init_Cartes; {.....}; Reset_Cartes;**

2.2 Instructions d'entrée/sortie basiques

>> **Ecrire_AO(port,valeur);** % avec port=0/1 et valeur =0-10 (volts)

Description : Ecrit sur un port ANALOGIQUE (OUTPUT AO0 ou AO1) de la carte 20428W. *Temperature(Vd)* est équivalent à *Ecrire_AO(0,T)*, mais la valeur de la température est automatiquement re-calibrée grâce à la table de conversion $T=f(Vd)$.

>> **valeur=Lire_AI(port);** % avec port=0/1

Description : Lit sur un port analogique (INPUT AI0 ou AI1) de la carte 20428W.

>> **Ecrire_DO(ligne,valeur);** % avec ligne=0-7 et valeur =0/1

Description : Ecrit un BIT sur le port digital à 8 bits N°1 (OUTPUT) de la carte 20428.

>> **valeur=Lire_DI(port);** % avec ligne=0 à 7 (valeur = 0 ou 1)

Description : Lit un bit du port DIGITAL à 8 bits (INPUT=1) de la carte A/D 20428W.

>> **Temperature(T);** % avec T entre 0 et 10.

Description : Contrôle de la température de speckle (port analogique AO0, de la carte 20428W). Equivalent à *Ecrire_AO(0,T)*, mais avec un appel à *Calibration.c* (voir table de conversion expérimentale, dans *cartes.h*).

2.3 Transfert de données entre le PPOS et l'ordinateur hôte.

>> **E=Recupere_Puce;** % (E est une matrice 24x24).

Description : Récupère la configuration courante d'étiquettes (ou spins) sur la puce.

Temps d'exécution : 9 ms.

>> **Envoie_Puce(E);** % (input = E, matrice 24x24).

Description : Envoie sur la puce une configuration arbitraire d'étiquettes (matrice E, 24x24).

Temps d'exécution : 14 ms.

>> **Interactions(p);** % (p entre 0 et 1).

Description : Configure les interactions électriques (à +1 ou à -1), de façon aléatoire (l'argument est la probabilité de tirage pour obtenir la valeur +1). Utile pour définir les modèle ferromagnétique (p=1), anti-ferromagnétique (p=0) et le verre de spins (p compris 0 et 1).

Temps d'exécution : 14 ms. (Remarque : la configuration de spins reste inchangée ; le poids des interactions électriques est commandé par l'entrée *f_pol* de la puce (typiquement 100mV).

2.4 Contrôle direct des modulateurs (SLM A ou B).

>> **Envoie_SLM(S,num,inv);** %S=24x24, num=0/1, inv=0/1 (image inverse)

Description : Envoie sur le SLM A ou B (num=0/1) la configuration des spins S, en mode "inverse" ou non. La matrice S est à valeurs *quaternaires* ; les codes (valeurs des sites de S) sont les suivants (voir routine S_SLM dans cartes.c) :

s=1, pour un codage double voie (0,1) donnant lieu à une force positive ;

s=0, pour un codage double voie (1,0) donnant lieu à une force négative ;

... enfin, pour permettre de réaliser des tests particuliers (*Test_holo.m*, §3):

s=2, pour les deux voies à 0 : (0,0) ;

s=3, pour les deux voies à 1 : (1,1).

Temps d'exécution : 12 ms.

>> **Blank(num,inv);** % num=0/1 (SLM A ou B), inv=0/1 (image inverse ou non)

Description : Remplit le SLM tout blanc (inv=0) ou *tout noir* (inv=1). Sert pour réaliser des "shutters" en utilisant les SLM binaires ferroélectriques (routine rapide).

Temps d'exécution : 0,3 ms (donc une fréquence maximale d'obturation de 3,3 kHz).

2.5 Instructions de "calcul"

2.5.1 Fonction de base.

>> **Update_White(to);**

Description : Mise à jour des sites "blancs" de la puce. *to* correspond au temps laissé aux photodétecteurs pour réaliser l'intégration du signal (en nanosecondes) *en plus* du temps d'exécution de la routine. Temps d'exécution (ms) : 0,22 ms pour *to*=0 (le temps d'intégration est alors 0,22ms), et 13,8ms + *to* pour *to*≠0.

>> **Update_Black(to);**

Description : Mise à jour des sites "noirs" de la puce.

Temps d'exécution (ms) : pour $to=0$: 0,22 ms (le temps d'intégration est alors 0,22ms) ; pour $to \neq 0$: 13,8ms + to .

>> **Update_2(nscan, to) ;**

Description : mise à jour du champ entier pour un coloriage binaire. $nscan$ est le nombre de mises à jour. Temps d'exécution (ms) : pour $to=0$: $0,09*nscan + 0,18$ ms (pour $nscan=1000$, $t \approx 90$ ms) / pour $to \neq 0$: $(27+to)*nscan + 0,66$ ms. Par exemple, pour $nscan=6$ et $to=0$, $t=0,7$ ms (nombre d'itérations pour réaliser l'optimisation déterministe ICM).

>> **Update_4(nscan, to) ;**

Description : mise à jour du champ entier en *simulant* un coloriage 4 (routine lente).

Temps d'exécution (ms) : pour $to=0$: $51*nscan+4,3ms$ / pour $to \neq 0$: $(69+to)*nscan+2$ ms.

2.5.2 Fonctions plus évoluées :

>> **E=Boucle_Electronique(Eo, T, nscan, col, to) ;**

Description : Echantillonneur de Gibbs en utilisant la puce SPIE600 (avec interconnexions aux 4 plus proches voisins purement électriques).

Entrées : Eo : champ d'étiquettes initial.

T : température de d'échantillonnage.

$nscan$: nombre d'échantillons (i.e. nombre d'itérations de la boucle).

col : définit le système de coloriage (2 ou 4).

to : temps (additionnel) d'intégration sur les photodétecteurs (en nanosecondes).

Sortie : Matrice E 24x24, résultat final de l'évolution à partir de Eo .

Temps d'exécution (ms): Pour un coloriage 2 : $to=0$: $0,08*nscan + 20$ ms / $to \neq 0$: $(27,8+to)*nscan+ 10ms$. Pour un coloriage 4 (simulé) : $to=0$: $51*nscan + 21$ ms / $to \neq 0$: $(70+to)*nscan+ 13$ ms.

>> **E=Recuit_Electronique(Eo, Ti, Tf, r, nscan, col, to) ;**

Description : Procédure de *recuit simulé* en utilisant seulement les interconnexions électriques entre PEs de SPIE600.

Entrées : Eo : état initial du champ d'étiquettes (pas important si Ti élevée)

Ti : température algorithmique (de speckle) initiale.

Tf : température finale.

r : coefficient de décroissance de la température.

$nscan$: nombre d'itérations par palier .

col : définit le système de coloriage (2 ou 4).

to : temps (additionnel) d'intégration sur les photodétecteurs (en nanosecondes).

Sortie : Matrice E 24x24, résultat final du recuit à partir de Eo .

Temps d'exécution (ms) : si n_{pal} est le nombre de paliers du recuit ($n_{iter}=\ln(Tf / Ti)/\ln(r)$), alors le temps d'exécution est à peu près égal à n_{iter} x temps d'exécution de la Boucle_Electronique($nscan, to$).

Commentaire : Il s'agit d'une routine de démonstration pour le modèle d'Ising ; cependant elle peut être utilisée pour le débruitage d'images à condition de projeter une image fixe O sur le SLM A en utilisant Envoie_SLM(0/1,O).

Routines utilisant la boucle optoélectronique (montage (O) du Chap.V,§1.1)

>> **E=Boucle_Optique(Eo, O, T, nscan, col, to) ;**

Description : Echantillonneur de Gibbs utilisant la boucle optoélectronique "non monolithique".

Entrées : *Eo* : champ d'étiquettes initial

O : image fixe (champ de contrainte à l'observation) sur le SLM-A.

nscan : nombre d'échantillons (i.e. nombre d'itérations de la boucle)

col : définit le système de coloriage (2 ou 4).

to : temps (additionnel) d'intégration sur les photodétecteurs (en nanosecondes).

Sortie : Matrice *E* 24x24, résultat final de l'évolution à partir de *Eo*.

Temps d'exécution :

Pour un coloriage 2 : $to=0$: $47*nscan + 51$ ms / $to\neq 0$: $(112+to)*nscan + 25$ ms.

Pour un coloriage 4 (simulé) : $to=0$: $238*nscan - 1,6$ ms / $to\neq 0$: $(305+to)*nscan - 36$ ms.

>> **E=Recuit_Optique(Eo, O, Ti, Tf, r, nscan, col, to) ;**

Description : Routine de recuit simulé en utilisant la boucle optoélectronique "non monolithique".

Entrées : *Eo* : état initial du champ d'étiquettes (pas important si *Ti* élevée)

O : image fixe (champ de contrainte à l'observation) sur le SLM-A.

Ti : température algorithmique (de speckle) initiale.

Tf : température finale.

r : coefficient de décroissance de la température.

nscan : nombre d'itérations par palier .

col : définit le système de coloriage (2 ou 4).

to : temps (additionnel) d'intégration sur les photodétecteurs (en nanosecondes).

Sortie : Matrice *E* 24x24, résultat final du recuit à partir de *Eo*.

Temps d'exécution (ms) : Si n_{pal} est le nombre de paliers du recuit $n_{iter} = \ln(Tf / Ti) / \ln(r)$, alors le temps d'exécution est à peu près égal à : n_{iter} x temps d'exécution de la *Boucle_Optique(Eo, O, T, nscan, col, to)*.

3. Programmes de mise en route

(cf. Chap.VI.§1)

Alignement et test du bus optique :

- Visualisation directe : *camera.m* (voir fig.VI.3).
- Vérification alignement SLMs : *test_alignement.m* (voir fig.VI.2).

Test du bus optique direct :

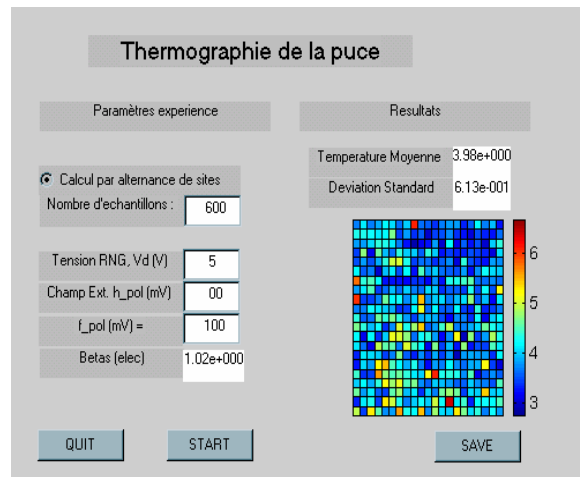
- *Test_Bus.m* (voir fig.VI.4).

Test de l'interconnexion holographique :

- *Test_holo.m* (voir fig.VI.5).
- *Test_Boucle.m* (voir fig.VI.6).

Uniformité éclairement :

- Eclairage du générateur de speckle : *thermographie.m* (voir figure ci-contre et fig.VI.10).
- Comparaison de l'éclairage entre les deux SLMs : *compare_slms.m*



Calibration des paramètres :

>> **P=Sigmoide(F,nech,col,to) ;**

Description : Calcul de la probabilité de mise à 1 en fonction de la force quantifiée (permet de construire la courbe sigmoïde, cf.Chap.VI.§1.3.2).

Sortie : *P* est la carte des probabilités de changement à +1 après *nech* mises à jour du champ avec un coloriage *col=2* ou *4*.

Entrées : force locale *électrique*, $F \in \{-4, -2, 0, 2, 4\} \times \beta_{S_elec}$ (β_{S_elec} est fonction de *f_pol*).

Commentaires : On peut également rajouter une contribution optique à la force locale en projetant une image sur la puce grâce au SLM-A.

4. Programmes de démonstration

4.1 Etude de l'équilibre thermodynamique et du recuit simulé.

-*Etude_Equilibre.m* (voir fig.III.7).

-*Etude_Recuit.m* (voir fig.III.8 pour le verre de spin et fig.VI.15 pour le débruitage d'images binaires).

Voici un exemple de code pour l'étude du recuit dans le cas du *Verre de Spin* (Chap.III.§6.1):


```

% Au préalable :
%   fixer le poids des interconnexions électriques : f_pol=100mV
%   fixer le champ externe global : h_pol=0 mV
%-----
--
Init_Cartes;           %initialisation des cartes électroniques
Interactions(0.8);    %fixe aléatoirement 80% des couplage à +1, les autres à -1.
Ti=10; Tf=0,01; r=0,95; nscan=15; %fixe les paramètres du recuit.
% Debut procédure de recuit simulé :
T=Ti;                 %température initiale.
while(r*T>Tf)
    Temperature (T); %fixe la température du speckle (table de correspondance
    %incluse dans la routine en C)
    E=Recupere_Puce; %lit le contenu du PPOS (champ d'étiquettes)
    see(E,1);        %visualise le champ d'étiquettes courant
    En(k)=energie_Ising(E,betas,h); %Calcule et sauvegarde l'energie du champ
    courant88
    Update_2(nscan,to); %misejour des sites parallèle (coloriage binaire).
    T=T*r;
end ;
E=Recupere_Puce % Recupère champ d'étiquettes final (voir fig.III.6 et fig.III.8).

```

4.2 Débruitage d'images binaires : *Debruitage.m*

Voici un extrait du code pour le débruitage d'images binaires en utilisant la boucle optoélectronique :

```

Données : -----
- I est la séquence d'images à débruiter (considéré comme une matrice 24x24xL, ou
L est la longueur de la séquence).
- Ti, Tf, r, nscan, col : paramètres du recuit.
- Eo : configuration d'étiquettes initiale (il n'y a pas à s'en préoccuper pour Ti>>Tc).
Routine : -----
    R=zeros(24,24,L); % allocation mémoire pour le résultat (séquence débruitée).
    for t=1:K
        O=R(:, :, t); % image binaire à débruiter.
        E(t, :, :) = Recuit_Optique(Eo, O, Ti, Tf, r, nscan, col, to); %recuit optique
    end;
    %R contient la séquence d'images débruitées (voir par exemple fig.VI.16 et 17).

```

⁸⁸ les paramètres de la fonction d'énergie sont calculés lors de la mise en route, cf.Chap.VI, §1.3.

4.3 Détection du mouvement : *Motion.m*

Voici un extrait du code pour la détection du mouvement en utilisant le PPOS :

```
Données : -----  
- I est la séquence de mouvement (considéré comme une matrice 24x24xL, ou L est la  
longueur de la séquence).  
- theta est le seuil de binarisation, calculé selon la formule Chap.IV,§6.2 en fonction des  
statistiques de niveau de gris de la séquence.  
- Ti, Tf, r, nscan, col : paramètres du recuit.  
- Eo : configuration d'étiquettes initiale (il n'y a pas à s'en préoccuper pour  $T_i \gg T_c$ ).  
Routine : -----  
MB=zeros(24,24,L); % allocation mémoire pour le champ d'étiquettes résultat final,  
c.à.d. le % masque binaire (MB) des objets mobiles.  
for t=2:K  
Ot=abs(I(t,,:)- I(t-1,,:)); % calcul de la différence inter-image  
CCTt=CCTt>theta; % calcul du champ binaire (par seuillage de Ot)  
Bt=E(t-1,,:).*CCTt; % préparation du champ binaire de contrainte  
% (".*"=produit matriciel point par point)  
E(t,,:)=Recuit_Optique(Eo, Bt, Ti, Tf, r, nscan, col, to); %recuit optique contraint  
end;  
%MB contient la séquence des masques binaires du mouvement (voir fig. VI.18).
```

Références bibliographiques

- [Aach93] Aach T., Kaup A., Mester R. "Statistical model-based detection in moving video", Signal Processing, Vol. 31, N.2., March 1993, pp. 165-180.
- [Aarts86] E.H.L. Aarts and P.J.M. Van Laarhoven, "A parallel statistical cooling algorithm", Proceed. of Symp. on The Theoretical Aspects of Computer Science, Springer Lecture Notes in Computer Science, pp. 87-97, Jan. 1986.
- [Aarts89] E.Aarts and J.Korst, "Simulated Annealing and Boltzmann Machines - A Stochastic Approach to Combinatorial and Neural Computing", John Wiley & Sons, (1989).
- [Alexan97] S.B.Alexander, "Optical Communication Receiver Design", (Chap.6), SPIE Tutorial Texts in Optical Engineering, Vol TT22, SPIE Press, (1997).
- [Andrew97] A.Kirk et al., "Compact optical imaging system for arrays of optical thyristors", Applied Optics, Vol. 36, No. 14, May (1997).
- [Ashok97] A.V.Krishnamoorthy and K.W.Goossen, Invited Paper, "Progress in optoelectronic-VLSI smart pixel technology based on GaAs/AlGaAs MQW modulators", International Journal of Optoelectronics, Vol. 11, No. 3, 181-198 (1997)
- [Ayliff99] M.H.Ayliffe et al., "Electrical, thermal and optomechanical packaging of large D optoelectronic device arrays for free-space optical interconnects", J.Opt.A: Pure Appl. Opt. 1, p.267-271, (1999).
- [Azenco87] R.Azencott, "Markov Fields and Image Analysis", 6^{ème} Congrès de Reconn. des Formes et Intell. Artificielle, Antibes, France, Nov.1987, pp.1183-1191.
- [Azenco88] R.Azencott, "Image Analysis and Markov Random fields", Proc. International Conf. on Indus. and Appl. Mathematics", SIAM, Philadelphia, pp.53-61 (1988).
- [Azenco92] R.Azencot (Ed), "Simulated Annealing : Parallelization Techniques", John Wiley & Sons, (1992).
- [Bar95] I.Bar-Tana et al., "Smart Pixels spatial light modulator for incorporation in an optoelectronic neural network", Optics Letters 20, No.3, pp 303-305, (1995).
- [Bauken99] V.Baukens et al., "Performances of optical multi-chip-module interconnects : comparing guided-wave and free-space pathways", J. Opt. A : Pure. Appl. Opt. 1, 255-261 (1999)
- [Belhai90] E.Belhaire, P. Garda, "An analog chip set of synchronous Boltzmann machines", Proc. ITG/IEEE Workshop on Microelec. for neural network, pp.80-87, 1990.
- [Bellon94] A.Bellon, J.P.Derutin, F.Heitz et Y.Ricquebourg, "Real-time collision avoidance at road crossings on board the Prometheus-ProLab 2 vehicle", Intelligent Vehicle, Octobre 1994.
- [Bernar92] T.Bernard, "Rétines intelligentes programmables : si nous parlions silicium pour voir...", Thèse de doctorat, Université de Paris-Sud, 1992
- [Bernar93] T.Bernard, B.Zavidovique, and F.Devos, "A programmable Artificial Retina", IEEE Journal of Solid State Circuits, 28(7):p.1130-1139 (1993).
- [Berter88] M.Bertero, T.Poggio, V.Torre, "Ill-posed problems in early vision", Proc.IEEE 76, pp.869-889 (1988).
- [Besag72] J.Besag, "Spatial interaction and the Statistical Analysis of Lattice Systems", J. Royal Stat. Soc. B 34 75-83 (1972).
- [Besag86] J.Besag, "On the Statistical Analysis of Dirty Pictures", Journal Royal Stat. Soc., Vol.B-48, N.3, pp.259-302 (1986).
- [Blake87] A.Blake and A.Zisserman, "Visual reconstruction", The MIT Press, Cambridge (1987).
- [Blanc98] N.Blanc et al., "Low-Power Microcameras Using CMOS Technology", Journées de Microtechnique 98, EPFL, octobre (1998).

- [Blostein91] S.D.Blostein and T.S.Huang, "Detecting small moving objects in image sequences using sequential hypothesis testing", IEEE transactions on Signal Processing, Vol.39, N.7, pp.1611-1629, Juillet (1991).
- [Boyd94] G.D.Boyd et al., "Mode locked pulse operation of GaAs/AlGaAs FET-SEED device smart pixels and saturation considerations", Appl. Phys. Lett., 65, 3108-3110, (1994).
- [Brenne98] K.H.Brenner, "Directional multiplexing for optical board to board interconnections", SPIE Vol. 3573, 0277-786X/98.
- [Buczyn99] R.Buczynski, R.Ortega, T.Szoplik, R.Vounckx, P.Heremans, I.Veretennicoff and H.Thienpont, "Fast optical thresholding with an array of optical thyristor differential pairs", J.Opt.A : Pure Appl. Opt. 1, pp.267-279, (1999)
- [Bulas93] J.Bulas-Cruz et al, "Real-Time motion detection and tracking", Proc. of the Scandinavian Conf. on Image Analysis SCIA'93, pp.515-522, (1993).
- [Caplie95] A.Caplier, "Modeles markoviens de detection de mouvement dans les séquences d'images : approche spatio-temporelle et mises en œuvre temps réel", thèse de doctorat de de l'Institut National Polytechnique de Grenoble, décembre (1995).
- [Carson89] J.E.Carson (Ed.), "Materials, devices, technologies and applications for Z-plane focal plane array technology", Proc. SPIE 1097 (1989).
- [Cassin00] A.Cassinelli, M.P.Y.Desmulliez, P.Chavel, "Dedicated Optoelectronic Stochastic Parallel Processor (OSPP) for real-time image processing: motion detection demonstration and design of a hybrid CMOS/SEED based prototype", (en préparation pour Optical Engineering).
- [Cassin98] A.Cassinelli, Ph. Lalanne, P.Chavel and I.Glaser, "Demonstration of Video-Rate Optoelectronic Parallel Processors for Noise Cleaning in Binary Images by Simulated Annealing", OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Proc. Vol 3490, pp. 163-166 (1998).
- [Catoni92] O.Catoni, "Rates of convergence for sequential annealing : a large deviation approach", dans R.Azencott, editor, *Simulated annealing parallelization techniques*, Chap.3, pp.25-35, J.Wiley & Sons, (1992).
- [Chavel87] P.Chavel, S.Laval et J.Taboury, "L'optique dans l'ordinateur", Revue Phys. Appl. 22, pp: 1215-1219 (1987).
- [Chavel99] P.Chavel, I.Glaser et A.A. Friesem, "Semi-Shift-Invariant Operation for Optical Computing", Final Report, European Commission : ERBC11*CT93-0004, May (1999).
- [Cheval89] R. Chevalier, "Memoires associatives de type neuronal : étude d'algorithmes, une réalisation électro-optique", Thèse de doctorat de l'ENST, (1989).
- [Chuang98] E.Chuang, W.Liu and D.Psaltis, « Holographic memory design for a petaflop superconducting computer architecture », OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Vol.3490, pp.343-5, (1998).
- [Chung67] K.L.Chung, "Markov Chains with Stationnary Transition Probabilities", Springer, N.Y., 1967.
- [Colin98] J.Colin, N.Landru, V.laude, S.Breugnot, H.Rajbenbach and J.P.Huignard, "High-speed photorefractive joint transform correlator using optimized nonlinear filters", OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Vol.3490, pp.26-29, June (1998).
- [Collin95] N.Collings et al, "Measurement on ferroelectric liquid cristal spatial light modulators: contrast ratio and speed", Applied Optics, 34(26):5928-5931, September (1995).
- [Cutron66] L.Cutrona et al., Proc.IEEE, 54, 1026, (1966).
- [Daino80] B.Daino et al., "Spatial coherence and index-profiling in optical fibres", Optica Acta, 26, (7), pp. 923-928, (1979).
- [Dainty84] J.C.Dainty, "Laser Speckle and related phenomena", Topics in Applied Optics, vol.9, Springer Verlag (1984).
- [Dames91] M.P.Dames, R.J.Dowling, P.McKee and D.Wood, "Efficient optical elements to generate intensity weighted spot arrays: design and fabrication", Appl.Opt., Vol.30, N°19, (1991).

- [Damman77] H.Dammann and E.Klotz, "Coherent Optical Generation and Inspection of Two-Dimensional Periodic Structures", *Opt.Acta*, 24, 505-515, (1977).
- [D'Asar93] L.A.D'Asaro et al., "Batch fabrication and operation of GaAs-Al_xGa_{1-x}As FET-SEED smart pixel arrays", *IEEE J. Quantum Electron.* 29, 670-677 (1993).
- [Davenp96] K.E.Devenport et al., "A Hyper Plane Smart Pixel Array for Packet based switching", submitted to IEEE/LEOS 1996 Summer Topical on Smart Pixels, Keystone, Colorado, August 7-9, (1996).
- [Derin87] H.Derin et al., "Modeling and Segmentation of Noisy and Textured Images Using MRF", *IEEE. Trans. Pattern Anal. and Machine Intell.* Vol.PAMI-9, N.1, pp.35-55, June (1989).
- [Derin89] H.Derin, S.Lakshmanan, "Estimation and Segmentation of Gibbs Random Fields Using Simulated Annealing", *IEEE Trans. Pattern Anal. and Mach. Intell.* Vol.II, No.8, Aug. (1989).
- [Déruti91] J.P.Dérutin et al., "A parallel vision machine : Transvision", *Proc. of Computer Architecture for machine perception*, B.Zavidovique et P.L.Wendel, Ed., pp.241-251, Dec. (1991).
- [Desmul99] M.P.Y.Desmulliez and B.S.Wherrett, "Trends in Hybrid-VLSI Optoelectronics for Optical Information Processing", à paraître dans *Optical interconnections and computing*, Oxford University Press, Oxford Series of Optical and Imaging Sciences, Editors : M.Lapp, A. Hasegawa, B.J.Snively, H. Starle, A.C. Tam, T. Wilson.
- [Diel91] Diehl N. "Object-Oriented Motion Estimation and Segmentation in Image Sequences", *Signal Processing : Image Communication* 3, pp. 23-56, (1991).
- [Dines96] J.A.B.Dines, "Smart Pixel Optoelectronic receiver based on a charge sensitive amplifier design", *J. Selected Topics in Quantum Elec.*, Vol.2, No.1, April (1996).
- [Display] Displaytech Inc.. 2602 Clover Basin Drive, Logmont, CO80503, www.displaytech.com.
- [Diu] B.Diu, C.Guthmann, D. Lederer, B.Roulet, "Le f erromagn etisme", Compl ement III.J, §IV dans "Physique Statistique", Hermann Ed., (1989).
- [Dumont96] C.Dumontier, "Etude et mise en  uvre temps r el d'un algorithme de detection de mouvement par approche markovienne", th ese de doctorat de l'Institut National Polytechnique de Grenoble, novembre (1996).
- [Dupre95a] A.Dupret, "Etude de g en rateurs al atoires pout machines cellulaires. Int egration d'une r tine stochastique opto- lectronique", Th ese Paris Sud, d ecembre (1995).
- [Dupre95b] A.Dupret, J.C.Rodier, D.Pr evost, E.Belhaire, P.Garda, "An opto-electronic implementation of simulated annealing", *ESCIRC'95*, 19-21, sept. (1995).
- [Duvill96] J.Duvillier, "Conception et r alisation d'une Carte auto-organis ee optique, lien entre r seaux de neurones formels et m moire associative", Th ese de doctorat de l'Universit  de Strasbourg I (ULP), f evrier (1996).
- [Essen92] D.C.Van Essen, C.H.Anderson, D.J. Felleman, "Information processing in the primate visual system: an integrated systems perspective", *Science*, 255:419-423, (1992).
- [Farhat85] N.H.Farhat, D.Psaltis, Aluizio Prata, Eung Paek, "Optical implementation of the Hopfield model", *Applied Optics* 24, No.10, pp 1469-1475, (1985).
- [Frauel99] Y. Frauel, "R seau de neurones auto-organisable tirant profit des interconnexions holographiques dynamiques inscrites dans un cristal photor fractif", Th ese de doctorat de l'Universit  de Paris Sud, Centre d'Orsay, d ecembre (1999).
- [Furuya97] T.Furuyama from Toshiba, Near-Future Interconnect Technology presented at 2nd. Int. Workshop on Future Information Processing Technology, Sapporo (1997).
- [Geman84] S.Geman and D.Geman, "Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images", *IEEE transaction on Pattern Analysis and Machine Intelligence* 6(6), pp. 721-741 (1984).
- [Geman90] D.Geman, S.Geman, C.Geffine and P.Dong, "Boundary Detection by Constrained Optimization", *IEEE Trans. Pattern Anal. & Mach. Intell.*, PAMI 12(7), pp. 609-628 (1990).
- [Gidas91] B.Gidas, "Metropolis-type Monte Carlo simulation algorithms and simulated annealing", Technical report, Division of Applied Mathematics, Brown University, (1991).

- [Gil93] S.Gil and T.Pun, "Multiresolution alerting for motion detection", dans 14^{ème} colloque du GRETSI, pp.903-906, Juan-les-Pins, France, Sept. (1993).
- [Glaser95] I.Glaser "Compact Lenslet Array Based Holographic Correlator/Convolver", Optics Letters 20, 1565-1567, (1995).
- [Goodma68] J.W.Goodman, "Introduction to Fourier Optics", McGraw-Hill, N.York, (1968).
- [Goodma85] J.W.Goodman, "Statistical Optics", John Wiley & Sons ed. (1985).
- [Goodma91] J.W.Goodman, "Four decades of optical information processing", Opt. Photonics News 2(2), 11-15 (1991).
- [Goosen94] K.W. Goosen et al., "GaAs MQW Modulators Integrated with Silicon CMOS", IEEE Phot. Tech. Letters, Vol.7, N.4, April (1995).
- [Guilfo96] P.S.Guilfoyle, D.S.McCallum, « High-speed low-energy digital optical processors », Opt.Eng. 35(2) 436-442 Feb. (1996).
- [Gyricon] <http://www.parc.xerox.com/dhl/projects/epaper/>
- [Haney98] M.W.Haney et al., "Compact acousto-optic system for real-time Synthetic Aperture Radar image formation", OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Vol.3490, pp.74-77, June (1998).
- [Hara90] K.Hara et al. "Differential optical switching at subnanowatt input power", Appl. Phys. Lett. 57 11, p.1075, (1990).
- [Harris90] J.G.Harris et al., "Analog Hardware for Detecting Discontinuities in Early Vision", Comp. and Neural System Prog., 216-276, Calif. Inst. ofTech. (1990).
- [Hasti70] W.K.Hastings, "Biometrika", 57, 97, (1970).
- [Heitz92] F.Heitz, P.Bouthemy, "Multimodal Estimation of Discontinuous Optical Flow Using Markov Random Fields", IEEE Trans. on PAMI, (1992).
- [Herem91a] P.Heremans et al. "The double heterostructure optical thyristor in optical information processing applications", Intern. Journal of Opt. Comp. 2, p.433, (1991).
- [Herem91b] P.Heremans et al. "Array-to-array transcription of optical information by means of surface light emitting thyristors", IEDM Tech. Digest 91, p.433, (1991).
- [Hinton84] G.Hinton, T.Sejnowski, D.Ackley, "Boltzmann Machines: constraint satisfaction networks that learn", Carnegie-Mellon Univ., Techn. Rep. CMU-CS-84-119 (1984).
- [Hinton94] H.S.Hinton, "Free Space digital optical systems", Proc. IEEE, 82, 1632-1649 (1994).
- [Hinton97] H.S.Hinton, "Progress in the smart pixel technologies", IEEE Journal of selected topics in quantum electronics, Special Issue on Smart Pixels, (1997).
- [Hiraba98] K.Hirabayashi et al., "Board-to-board free-space optical interconnections passing through boards for a bookshelf-assembled Tb/s-class ATM switch", Applied Optics, Vol. 37, No. 14, May (1998).
- [Hirai92] Yuzo Hirai, "Hardware implementation of neural networks in Japan", Neurocomputing, No.5, pp.3-16 (1992).
- [Hopfie82] J.J.Hopfield, "Neural networks and physical systems with emergent collective computational abilities", Proc. Nat. Acad. of Sci. (USA) 79, 2554-2555, (1982).
- [Hopfie85] J.J.Hopfield and D.W.Tank, "Neural Computation of Decisions in Optimization Problems", Biol. Cyber. 52, pp 141-152 (1985).
- [Horn81] B.K.P Horn, B.G. Schunck, "Determining Optical Flow", Artificial Intelligence, Vol. 17, pp.185-203 (1981).
- [Hsu84] Y.Z.Hsu et al., "New likelihood test methods for change detection in image sequences", Computer Vision, Graphics and Image Proc., CVGIP-26, pp.73-106, (1984).
- [Huang89] K.S.Huang et al., "Binary Image Algebra and digital optical cellular image processor design", Computer. Vision Graph. Image, Proc. 45, 295-345, (1989).

- [Hutchi86] J.M.Hutchinson and C.Koch, "Simple analog and hybrid networks for surface interpolation", Neural Networks for Computing, J.S.Denker, ed., American Institute of Physics, New York, pp. 235-239, (1986).
- [Jain79] R.Jain, H.H.Nagel, "On the Analysis of Accumulative Difference Pictures from Image Sequences of Real World Scenes", Trans. on PAMI, Vol.1, N.2, pp.13-34, Apr. (1979).
- [Jenkin84] B.K.Jenkins, P.Chavel, R.Forchheimer, A.A.Sachuk and T.C.Strand, "Architectural implications of a digital optical processor", Appl. Optics, Vol.23, No:19, pp.3465-74, (1984).
- [Jöhnck99] M.Jöhnck, B.Wittman and A.Neyer, "64 channel 2D POF-based optical array interchip interconnect", J.Opt.A : Pure Appl. Opt.1, pp: 313-316, (1999).
- [Johnso93] K.M.Johnson et al., "Smart spatial light modulators using liquid crystal on silicon", IEEE Journal of Quantum Electronics, vol. 25, No.2, p. 699-714, February (1993).
- [Jourda93] E.Jourdain, "Réalisation d'un générateur de tableaux de nombres aléatoires utilisant le speckle", Rapport de stage de DEA (Optique et Photonique), juin (1993).
- [JTEOS99] Journal of Optics A, Special issue in optics in computing, Vol.1, No. 2, March (1999).
- [Kaloye97] A.E.Kaloyeros, et al., *Active Interconnect Packaging scheme (AIP)*, Semiconductor International 20, 115, (1997).
- [Karman90] K.P.Karman, "Time recursive motion estimation using dynamical models for motion prediction", IEEE Internat.Conf.on Patt.Recogn., Atlantic City, pp.268-270, June (1990).
- [Kato92] Z.Kato, et al., "Satellite Image classification Using a Modified Metropolis Dynamics", Proc. ICASSP 92, San Francisco, USA, March. (1992).
- [Kirk97] A.Kirk et al., Appl. Opt. 25, 3070-8, (1997).
- [Kirkpa83] S.Kirkpatrick et al., "Optimization by Simulated Annealing", Science, V.220, 671-80, (1983).
- [Knupe95] B.Knupfer et al., "Cascadable differential PnpN optoelectronic switch operating at 50 Mbit/s with ultrahigh optical input sensitivity", Electron. Lett. 31, pp.485-486, (1995).
- [Koba87] H.Kobakate et al., "Measurement of two dimensional movement of traffic by image processing", Proc. of ICASSP, pp.614-617, (1987).
- [Koch86] C.Koch, A.Marroquin and A.Yuille, "Analog neuronal networks in early vision", Proc.Natl.Acad.Sci. USA 83, pp.4263-4267, (1986).
- [Koch89] C.Koch, "Seeing Chips: Analog VLSI Circuits for Computer Vision", Neural Computation 1, 184-200 (1989).
- [Konrad88] J.Konrad & E.Bubois, "Estimation of image motion fields : bayesian formulation and stochastic solution", in Proc. Int. Conf. Acoust., Speech, Signal Processing, pp.1072-1075, N.Y., USA, (1988).
- [Koppa95] P.Koppa, "Commutation de données par reconnaissance d'adresse binaire", Thèse de doctorat de l'Université de Paris XI, Orsay, octobre (1995).
- [Krish97a] A.V.Krishnamoorthy and Keith W. Goossen, Invited Paper, "Progress in optoelectronic-VLSI smart pixel technology based on GaAs/AlGaAs MQW modulators", International Journal of Optoelectronics, Vol. 11, No. 3, 181-198. (1997).
- [Krish98b] A.V.Krishnamoorthy et al. "Vertical Cavity Emitting Lasers Flip-Chip bonded to CMOS circuits", *Post Deadline Paper, OC'98* (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., (1998).
- [Kuijk95] M.Kuijk et al, "Down-scaling differential pairs of depleted optical thyristors", IEEE Phot. Techn. Lett. 7, (6), 646-648, (1995)
- [Kurians95] A.Kurianski and M.Nieniewski, "A model of the MRF with three observation sources for obtaining the masks of moving objects", Proc. of the 9th SCIA, pp.931-940, Uppsala, Sweden, Juin (1995).
- [Lalan90a] P.Lalande and P.Bouthemy, "A Statistical Approach to the Detection and Tracking of Moving Objects in an Image Sequence", Signal Proc.V : Theories et applications, pp.947-950, (1990).

- [Lalan90b] P.Lalande, "Détection du mouvement dans les séquences d'images selon une approche markovienne ; application à la robotique sous-marine", Thèse de l'Univ. de Rennes I, (1990).
- [Lalan95a] Ph.Lalanne et al., "Gaussian random number generation by differential detection of speckles", *Optical Engineering*, Vol. 34, No.6, p.1835-1837, June (1995).
- [Lalan95b] Ph.Lalanne et al., "Contribution à la réalisation de machines optoélectroniques parallèles pour l'algorithme de recuit simulé", Rapport de synthèse final, DRET 92-139, sept. (1995).
- [Lalann89] Ph.Lalanne, "Les réseaux de neurones formels et leurs réalisations optoélectroniques : génération de tableaux de nombres aléatoires", thèse de doctorat de l'Université de Paris XI, Centre d'Orsay, (1989).
- [Lalann90] Ph. Lalanne et al., "2D optical generator of updating probabilities for VLSI implementations of Boltzmann Machines", *Internat. Journ. Of Opt. Comp.* 1(1), pp. 25-30 (1990).
- [Lalann93] Ph.Lalanne and P.Chavel, P.Garda and F.Devos, "Optoelectronic retinas that perform stochastic global optimization", *Opt.Lett.*, pp.1564-1566 (1993).
- [Lalann95] Ph. Lalanne, E. Belhaire, J.C. Rodier, A. Dupret, P. Garda and P. Chavel, " Gaussian random number generation by differential detection of speckles ", *Opt. Eng.* 34, pp 1835-1837 (1995).
- [Landau67] L.Landau, E. Lifchitz, "Physique Statistique", §141, Ed. Mir, Moscou (1967).
- [Lentin88] A.L.Lentine, H.S.Hinton and D.A.Miller, "Symmetric self-electro-optics effect device: Optical set-rest latch", *Appl.Phys.Letter*, 52:1419-1421, (1988).
- [Lentin94] A.L.Lentine, L.M.Chirovsky and T.K.Woodward, "Optical energy considerations for diode-clamed smart pixel optical receivers", *IEEE Journal of Quantum Electronics*, Vol.30, No.5, pp.1167-1171, May (1994).
- [Letang93] J.M.Letang, "Intégration temporelle et régularisation statistique appliquées à la détection d'objets mobiles dans une séquence d'images". Thèse de doctorat de l'INPG, (1993).
- [Li96] Y. Li et al., "VCSEL-array-based angle-multiplexed optoelectronic crossbar interconnects", *Appl. Opt.*, Vol.35, No.8, March (1996).
- [Li99] Y.Li, and al., "clock delivery using laminated polymer fibre circuits", *J.Opt.A : Pure Appl. Opt.*1, 239-243, (1999).
- [Lin93] S. Lin, A.Grot, J.Luo and D.Psaltis, "GaAs optoelectronic neuron arrays", *Applied Optics*, Vol.32, No.8, , pp1275-1288, (1992).
- [Little88] M.J.Little and J.Grinberg, "The 3-D computer : an integrated stack of WSI wafers", in *Wafer-Scale Integration*, Klumer, New York, Chap.8, (1988).
- [Lohman91] A.W.Lohmann, "Image formation of dilute arrays for optical information processing", *Optics Communications*, Vol. 86 365-370, (1991).
- [Lukowi98] P.Lukowicz et al. "Design of an opto-electronic VLSI/parallel fibre bus", *J. Opt.A: Pure Appl. Opt.* 1 367-370, (1999).
- [Luthon95] F.Luthon, V.G.Popescu et A.Caplier, "An PRF based motion detection algorithm implemented on analog resistive network". Dans 3^e European Conference on Computer Vision, pp.167-174, Stockholm, Sweden, Mai 1994.
- [Mao93] C.C.Mao et al., "Optoelectronic array that computes error and weight modification for a bipolar optical neural network", *Appl. Optics* 32, No.8, pp1290-1296 (1993).
- [Marro85a] J.L.Marroquin, "Probabilistic solution of inverse problems", PhD thesis, MIT, Artificial Intell. Lab., (1985).
- [Marro85b] J.Marroquin, "Surface Reconstruction Preserving Discontinuities", MIT A.I.Memo 792, August (1985).
- [Marron86] J.Marron et al., "Generation of random arrays using clipped laser speckle", *Appl. Optics* 25 (1), (1986).
- [Marroq87] J.Marroquin, S.Mitter, T.Poggio, "Probabilistic solution of ill-posed problems in Computational Vision", *Journal of the American Stat. Assoc.*, 82(397), pp.76-89, (1987).

- [Marvall95] D.Marvall et al., "Mobile Detection Based on Histogram Difference", Proc. of the 6th CAIP, Prague, Czech Republic, pp.286-293, September (1995).
- [Masa99] P.Masa et al., "10 mW CMOS Retina and Classifier for Handheld, 1000 images per Second Optical Character Recognition System", Proceedings of the IEEE International Solid-State Circuits Conference, 202 (1999).
- [Matsuo95] S.Matsuo et al., "Monolithically integrated photonic switching device using an MSM PD, MESFETs, and a VCSEL", IEEE Photonics Technology Letters, Vol. 7, No. 10, pp. 1165-1167, October (1995).
- [McAula91] A.D.McAulay, "Optical computer architectures : the application of optical concepts to next generation computers", John Wiley & Sons Ed., (1991).
- [McCorm93] F.B. McCormick, T.J. Cloonan, F.A.P. Tooley, A.L. Lentine, J.M. Sasian, J.L. Brubaker, R.L. Morrison, S.L. Walker, R.J. Crisci, R.A. Novotny, S.J. Hinterlong, H.S. Hinton, and E. Kerbis, "A six-stage digital free-space optical switching network using S-SEEDs", App.Opt., vol. 32, N.26, Sept. 10, pp.5153-5171, (1993).
- [McCorm94] F.B. McCormick, T.J. Cloonan, A.L. Lentine, J.M. Sasian, R.L. Morrison, M.G. Beckman, S.L. Walker, M.J. Wojcik, S.J. Hinterlong, R.J. Crisci, R.A. Novotny, H.S. Hinton, and E. Kerbis, "A 5-stage free-space optical switching network with field-effect transistor self-electro-optic-effect smart pixel arrays", App.Opt., vol. 33, N.8, March 19., pp.1601-1618, (1994).
- [McKnig94] D.J. McKnight et al., "256x256 liquid-cristal-on-silicon spatial light modulator", App.Opt. Vol.33, No.14, 10 May (1994).
- [Mead88] C.Mead and M.A.Mahowald, "A silicon model of early visual processing", Neural Networks 1:91-97, (1988).
- [Mead94] C.Mead, "Scaling of mos technology to submicrometer feature sizes", VLSI Signal Processing, 8, p.9-25, (1994).
- [MediaL99] Media Lab MIT, Electronic Ink.
- [Meindl95] J.D.Meindl, « Low Power Microelectronics : Retrospect and Prospect », Proc. of the IEEE, vol.83, No.4, April, (1995).
- [Memin93] E.Memin, "Algorithmes et architectures parallèles pour les approches markoviennes en analyse d'images", thèse de doctorat de l'université de Rennes I, juin (1993).
- [Metrop53] N.Metropolis et al. "Equation of state calculations by fast computing machines", J.Chemical. Phys. Vol.21, 1087-1091, (1953).
- [Mhani97] A.Mhani, "Rétine en silicium ou caméra intelligente", thèse de doctorat de l'Institut National Polytechnique de Grenoble, octobre (1997).
- [Millar51] W.Millar, "Some general theorems for non-linear systems processing", Philosophical Magazine 42, pp1150-60, (1951).
- [Miller87] D.A.B.Miller, "Quantum wells for optical information processing", Optical Engineering, 26(5):368-372, (1987).
- [Miller97] D.A.B.Miller, H.M.Ozaktas, "The bit-rate capacity of electrical intrconnects from the aspect ratio of the system architecture", J. of Parall. and Distr. Comp., 4.42-52, (1997).
- [Millma72] J.Millman and C.C.Halkias, "Integrated Electronics", McGraw-Hill International Editions, Electrical and Electronic Engineering Series, (1972).
- [Miyaza99] D.Miyazaka, S.Masuda, K.Matsushita, "Alignment-free optical modules using optical microconnectors", J.Opt.A : P.Appl. Opt. 1, pp.333-337, (1999).
- [Moigna97] R.Moignard, "Les composants à cristal liquide ferroélectrique sur circuit intégré : Application à la commutation optique en espace libre", thèse de doctorat de l'Université de Bretagne Occidentale, janvier (1997).
- [Moore91] A.Moore, J.Allman and R.M.Goodman, "A real-time neural system for color constancy", IEEE Transaction on Neural Networks, 2(2):237-247, (1991).

- [Morris85] G.M.Morris, "Optical computing by Monte Carlo methods", *Optical Engineering* 24 (1), pp. 86-90, (1985).
- [Mumbru00] J.Mumbru et al., "Optically Programmable Gate Array", in *Optics in Computing 2000*, Roger A. Lessard, Tigran Galstian, Ed., SPIE Vol.4089, pp.763-771, (2000).
- [Mumbru99] J.Mumbru, G.Zhou, S.Ay, X.An, G.Panotopoulos, F.mok, and D.psaltis, "Optically Reconfigurable Processors", *A Critical Review 1999 Euro-American Workshop on Optoelectronic Information Processing*, P.Refregier, B.javidi, Vol.CR74, pp.265-288, SPIE, (1999).
- [Murray87] D.W.Murray et al., "Scene Segmentation from Visual Motion Using Global Optimization", *IEEE. Trans. Pattern. Anal. and Mach. Intell.* Vol. PAMI-9, No.2, pp.220-228, Jan. (1987).
- [Ohta90] J.Ohta, K.Kojima, Y.Nitta, S.Tai, K.Kyuma, "Optical neurochip based on a three-layered feed-forward model", *Optical Letters* 15, No.23, pp.1362-1364, (1990).
- [OIIC99] Advanced research initiative in microelectronics, IST programme for Future and Emerging Technologies : *Technology roadmap for Optoelectronic Interconnects for Integrated Circuits* (MEL-ARI OPTO), European Commission, second edition, September (1999).
- [OPTOBU] D.B.Schwartz et al., "OPTOBUS™ I: performance of a 4Gb/s optical intrconnect", *Proc.IMPPOI'96* (San Antonio, TX), pp.256-263, Oct. (1996).
- [Ozakta90] H.M.Ozatkas et al., "Lower bound for the communication volume required for optically interconnected array of points", *J.O.S.A-A* 7, No.11, pp.2100-2106, November (1990).
- [Ozakta96] H.M.Ozaktas and D.Miller, "Digital Fourier Optics", *Appl.Opt.*, Vol.35, N.8, pp.1212-1219, (1996).
- [Phong75] B.T.Phong, "Illumination for computer generated pictures", *Communications of the ACM*, Vol.18, N.6, pp.311-317, (1975).
- [Plant95] D.V.Plant and al, "A 4x4 VCSEL/MSM Optical Backplane Demonstrator", 1995 LEOS Annual Meeting", Post Deadline Paper PD5, 1995.
- [Plant95] D.V.Plant et al, "A 4x4 VCSEL/MSM Optical Backplane Demonstrator", 1995 LEOS Annual Meeting", Post Deadline Paper PD5, 1995.
- [Poggio85] T.Poggio and C.Koch, "Ill-posed problems in early vision: from computational theory to analogue networks", *Proc.R.Soc.Lond.B*226, pp 303-323, (1985).
- [Prémon94] G.Prémont, Ph.Lalanne, P.Chavel, P.Heremans, M.Kuijk, "Photothyristor-based stochastic elementary processor", *Proc. Opt. Comp. Int. Conf.*, Edimburgh, UK, août (1994).
- [Prémon99] G. Prémont, "Photothyristors PnpN et recuit simulé optoélectronique pour la vision bas-niveau", Thèse de l'université de Paris-Sud, Orsay, (1999).
- [Prévos94] D.Prévost, Ph.Lalanne, L.Garnero et P.Chavel, "Quasi-static algorithm for image restauration preserving discontinuities", *SPIE Proc.* Vol.2304, pp.156-164, (1994).
- [Prévos95] D.Prévost, "Rétines artificielles stochastiques : algorithmes et mise en œuvre", thèse de doctorat de l'Université de Paris-Sud, Centre d'Orsay, décembre (1995).
- [Rietma89] E.A.Rietman et al., "Amorphous silicon photoconductive arrays for artificial networks", *Appl.Opt.* 28, No.15 pp.3474-3748, (1989).
- [Rolsto96] D.R.Rolston, B. Robertson, H.S. Hinton, and D.V.Plant, "Analysis of a microchannel interconnect based on the clustering of smart-pixel-device windows", *Applied Opt.* Vol. 35, No. 8, 1220-1233, (1996).
- [Seyd91] I.Seyd-Darwish, "Etude et réalisation d'un automate cellulaire optoélectronique parallèle", Thèse de doctorat de l'Université de Paris Sud, Orsay, décembre (1991).
- [SIA97] The National Technology Roadmap for Semiconductors (Sematech. Inc., San Jose, CA : Semiconductor Industry Association), (1997).
- [Sinzing98] S.Sinzinger, "Planar optics as the technological platform for optical interconnects", Invited lecture OC'98, P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Vol.3490, pp.40-43, June (1998).

- [Skifst89] K.Skifstadt, R.Jain, "Illumination independent change detection for real world image sequences", Computer Vision, Graphics and Image Proc., CVGIP-46, pp.387-399; (1989).
- [Smith95] B.Smith, "Interconnection networks for shared memory parallel computers", Proc. 2nd Int. Conf. On Massively Parallel Processing Using Opt. Interconnects, (1995).
- [Sokal89] A.D.Sokal, "Monte Carlo Methods in Statistical Mechanics : Foundations and New Algorithms", Troisième cycle de la physique en Suisse Romande, Semestre d'été (1989).
- [SPOEC] *Smart-Pixel Optoelectronic Connection*. Projet européen visant la construction d'un commutateur de type cross-bar 64x64 en utilisant des interconnexions en espace libre et des puces hybrides InGaAs/Si-CMOS (SPA à entrées et sorties optiques pour la reconnaissance et le routage de paquets de données). Voir par exemple : S.J.Fancey et al, "Optical components of the SPOEC project", J.Opt.A : Pure Appl. Opt.1, pp : 304-306. (1999).
- [Stelma85] P.Stelmaszyk et al., "Analyse de scènes dynamiques par recherche des contours en mouvement", 5^{ème} Congrès de Reconnaissance des formes et Intelligence Artificielle., AFCET/INRIA, Grenoble, France, pp.1181-1189, Nov. (1985).
- [Stone71] H.S.Stone, "Parallel Processing with the Perfect Shuffle", IEEE Trans. on Comp., C-20, (1971).
- [Streib89] N.Streibl, "Beamshaping with optical array generators", J.Mod. Opt. 36, 1559, (1989).
- [Szyman96] T.H.Szymanski and H.S.Hinton, "Reconfigurable optical backplane for parallel computing and communications", Appl. Opt. 35, No.8, pp.1253-1268, (1996).
- [Tabour88] J.Taboury, J.M.Wang, P.Chavel, F.Devos and P.Garda, "Optical cellular processor architecture.", Appl. Opt. Vo.27, N°9, pp.1643-1650, (1988).
- [Terzop86] D.Terzopoulos, "Image Analysis using Multi-grid relaxation methods", IEEE, Trans. Pattern. Anal. and Machine Intell., Vol.PAMI-8, N.2, pp.129-139, March (1986).
- [TRANSP] C.H.Chen, et al., "Architecture and Optical design for TRANslucent Smart Pixel Array (TRANSPAR) Chips", OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE Vol.3490, pp.316-319, June (1998).
- [Ulst73] M.S.Ulstad, "An algorithm for estimating small scale differences between two digital images", Patt.Recogn., Vol.5, pp.323-333, (1973).
- [Vasile93] P.Vasilev et al., "High-power, low-jitter encoded picosecond pulse generation using an RF-locked, Q-switched multicontact GaAs/AlGaAs diode laser", Elect. Lett. 19, p.1593, (1993).
- [Vendie96] O.Vendier et al., "A 155 Mb/s digital transmitter using GaAs thin film LEDs bonded to silicon driver circuits", 1996 Topical Meeting on Smart Pixels, Keystone CO, Aug. (1996).
- [Versha98] G.Vershauffelt et al., "Experimental demonstration of multi-channel micro-optical bridge for multi-Gb/s, free-space intra-MCM interconnects", OC'98 (Bruges), P.Chavel, D.A.B.Miller, H.Thienpont Ed., SPIE, V.3490, 44-47, June (1998).
- [Vieren88] C.Vieren, "Segmentation de scènes dynamiques en temps réel. Application au traitement de séquences d'images pour la surveillance des carrefours routiers", PhD thesis, Univ. des Sciences et Techniques de Lille, France, (1988).
- [Walker98] A.C.Walker et al. , "Optoelectronic systems based on InGaAs-CMOS SPA and Free-Space optical interconnects", Applied Opt. 37, N°14, pp.2822-2830, May (1998).
- [Walker98] A.C.Walker et al. , "Optoelectronic systems based on InGaAs-CMOS SPA and Free-Space optical interconnects", Applied Opt. 37, N°14, pp.2822-2830, May (1998).
- [Walker98] A.C.Walker et al. , "Optoelectronic systems based on InGaAs-CMOS SPA and Free-Space optical interconnects", Applied Opt. 37, N°14, pp.2822-2830, May (1998).
- [Walker99] A.C.Walker et al. "Design and implementation of an optoelectronic crossbar switch containing a Terabit/s free-space optical interconnect", accepted to IEEE J. Selected Topics in Quant. Electron., (1999).
- [Walker99] A.C.Walker et al. "Design and implementation of an optoelectronic crossbar switch containing a Terabit/s free-space optical interconnect", accepted to IEEE J. Selected Topics in Quant. Electron., (1999).

Références bibliographiques

- [Wiklund87] J.Wiklund, "Image sequence analysis for tracking moving objects", PhD thesis, Linkoping Univ., Computer Vision Lab., Mars (1987).
- [Willia86] G.F.Williams and H.P.LebLANC, "Active feedback lightwave receivers", J.of Lightwave technology, Vol. 4, No.10, Oct. (1986).
- [Woodw96a] T.K. Woodward et al., "1 Gb/s two-beam transimpedance smart-pixel optical receivers made from hybrid GaAs MQW modulators bonded to 0.8 μ m silicon CMOS", IEEE Photon. Tech. Lett., Vol.8, no.3, 423-24, March (1996).
- [Woodw96b] T.K.Woodward et al., "Optical receivers for optoelectronic VLSI", IEEE Journal of Selected Topics in Quantum Electronics, Vol. 2, No. 1, pp. 106-116, April (1996).
- [Woodwa94] T.K. Woodward et al., "Experimental sensitivity studies of diode-clamped FET-SEED smart-pixel optical receivers", IEEE, J. Quantum Electron., vol.30, no.10, pp.2319-24, Oct. (1994).
- [Woodwa97] T.K.Woodward et al., "Demultiplexing 2.48 Gb/s optical signals with CMOS receiver array based on clock-sense-amplifier", IEEE Phot. Technol. Lett. 9, p. 1146-8, (1997).
- [Worche96] T.L. Worchesky et al., "Large arrays of spatial light modulators hybridized to silicon integrated circuits", Appl. Opt., Vol.35, No.8, March (1996).
- [Wu99] J.M. Wu, Ch.B. Kuznia, B.Hoanca, Ch.H. Chen and A.A. Sawchuk, "Demonstration and architectural analysis of complementary metal-oxide semiconductor/multiple-quantum-well smart-pixel array cellular logic processors for single-instruction multiple-data parallel-pipeline processing", Appl.Opt., Vol.38, No.11, pp.2270-2281, April (1999).
- [Wyatt92] J.L.Wyatt et al, "Analog VLSI Systems for Image Acquisition and Fast Early Vision Processing", Int. J. of Computer Vision, 8(3), 217-230 (1992).
- [Yablon87] E.Yablonovitch et al., "Extreme selectivity in the liftoff of epitaxial GaAs films", Applied Physics, vol. 51, No 26, p.2222-2224, (1987).
- [Yu93a] A.Yu et al., "1047 nm laser diode master oscillator Nd:YLF power amplifier system" Elect. Lett. 29, pp: 678-679, (1993).
- [Yu93b] S.Yu and S.R.Forrest, "Implementations of Smart Pixels for optoelectronic processors and interconnection systems. SEED-based technology and comparison with optoelectronic gates", J.Lightwave Technol. 11, pp: 1670-80 (1993)
- [Zavido81] B.Zavidovique and G.Stammon, "Bilevel Processing of Multilevel Pictures", Patt. Recog. and Image Proc. Conf., Dallas, Août 1981
- [Zerubi90] J.Zerubia et al., "MFA using compound Gauss-MRF for edge detection and image restoration". Rapport interne de l'INRIA, Sophia-Antipolis, N.1295, Oct. 1990.
- [Zerubi92] J.Zerubia et al., "Modélisation markovienne en vision par ordinateur. Différentes techniques d'optimisation", GDR 134, Trait. du signal et des images, Paris, sept. 1992, pp.167-184.