



SPIM

Thèse de Doctorat



UFC

école doctorale **sciences pour l'ingénieur et microtechniques**
UNIVERSITÉ DE FRANCHE-COMTÉ

Titre

Sous-titre

■ Gilles PERROT

SPIM

Thèse de Doctorat



école doctorale sciences pour l'ingénieur et microtechniques
UNIVERSITÉ DE FRANCHE-COMTÉ

N° | X | X | X |

THÈSE présentée par

Gilles PERROT

pour obtenir le

Grade de Docteur de
l'Université de Franche-Comté

Spécialité : **Informatique**

Titre

Sous-titre

Soutenue le 17 septembre 2012 devant le Jury :

Incroyable HULK	Rapporteur	Professeur à l'Université de Gotham City Commentaire secondaire
Super MAN	Examineur	Professeur à l'Université de Gotham City
Bat MAN	Directeur de thèse	Professeur à l'Université de Gotham City

SOMMAIRE

1	Introduction	7
2	Les processeurs graphiques (GPU) NVidia®	11
2.1	Pourquoi ?	11
2.2	Comment ?	12
2.2.1	Le matériel	12
2.2.2	Le logiciel	13
2.2.3	l'Occupancy	14
3	Le traitement des images bruitées	17
3.1	Modèle d'image bruitée	18
3.2	Modèles de bruit	18
3.2.1	Le bruit gaussien	18
3.2.2	Le speckle	18
3.2.3	Le bruit "sel et poivre"	19
3.2.4	Le bruit de Poisson	19
3.3	Les techniques de réduction de bruit	19
3.3.1	Les opérateurs de base	21
3.3.1.1	Le filtre de convolution	21
3.3.1.2	Le filtre médian	21
3.3.1.3	Le filtre bilatéral	22
3.3.1.4	Les algorithmes de filtrage par dictionnaire	24
3.3.2	Les algorithmes de filtrage par patches	24
3.4	Les implémentations GPU des algorithmes de filtrage	26
3.4.1	Le filtrage par convolution	26
3.4.2	Le filtre médian	26
3.4.3	Le filtre bilatéral	27
3.4.4	Les filtres par patches	29
3.5	Les techniques de segmentation	29
3.5.1	Analyse d'histogramme	30

3.5.2	Partitionnement de graphe	32
3.5.3	kernel-means, mean-shift et apparentés	33
3.5.4	Les contours actifs, ou <i>snakes</i>	35
3.5.5	Méthodes hybrides	37
3.6	Les implémentations GPU des techniques de segmentation	37
3.6.1	Calcul d'histogramme	38
3.6.2	Partitionnement de graphe	38
3.6.3	K-means, mean-shift et apparentés	39
3.6.4	Snakes et Level set	41
3.6.5	Algorithmes hybrides	44
3.7	Conclusion	45
4	La segmentation par snake polygonal orienté régions	47
4.1	Présentation de l'algorithme	47
4.1.1	Formulation	47
4.1.2	Optimisation des calculs	48
4.1.3	Implémentation séquentielle	50
4.1.4	Performances	51
4.2	Implémentation parallèle GPU du snake polygonal	54
4.2.1	pré-calculs des images cumulées	54
4.2.2	Calcul des contribution des segments	55
4.2.2.1	Cas particulier des segments dont la pente k vérifie $ k \leq 1$	59
4.2.3	Performances	59
4.2.4	Discussion sur l'initialisation	61
4.2.5	Conclusion	62
5	Le filtrage des images sur GPU	67
5.1	Algorithme de réduction de bruit par recherche des lignes de niveaux	67
5.2	Filtre médian	67
5.3	Filtres de convolution	67
6	Conclusion générale	69

INTRODUCTION

Nous percevons le monde au travers le filtre de nos cinq sens, parmi lesquels la vue et plus largement la vision joue un rôle essentiel et unique. Elle nous fournit de précieuses données sur les objets qui nous entourent et leur comportement, comme leur couleur, leur forme, leur volume, leur texture mais aussi leur position, vitesse et accélération relative à notre propre mouvement.

Notre vision est aussi l'appareil sensoriel grâce auquel ont pu naître la lecture et l'écriture, au travers de la reconnaissance des signes qui composent les mots et la ponctuation, ainsi que des groupes de signes qui forment les mots et des groupes de mots qui donnent le sens au texte écrit.

Très tôt, l'être social qu'est l'homme a exprimé le désir et le besoin de partager avec d'autres hommes ce qu'il voyait ou avait vu. Dès lors, il a simplifié, modélisé et inventé des représentations pour les adapter à sa perception et aussi aux contraintes externes. Ses représentations visuelles ont tout d'abord été statiques, exécutées sur des murs de roche, puis il a un jour été capable de les emporter avec lui pour transmettre des messages, partager des informations et des émotions.

Les images prennent ainsi diverses formes selon le rôle qu'on leur attribue : véhiculer des informations textuelles, géométriques ou techniques au travers de schémas conceptuels, ou reproduire au mieux une réalité observée comme le fait la photographie, mais aussi provoquer des émotions au travers de représentations abstraites comme des peintures.

Certains traitements appliqués à ces représentations sont déjà très anciens ; le fait d'y dissimuler des informations supplémentaires (stéganographie) remonte par exemple à l'antiquité et à été développé sous de multiples formes depuis, tant la nécessité de transmettre secrètement des informations à toujours été un enjeu particulièrement important.

Toutefois, la découverte et la maîtrise de l'électricité ont ouvert des voies nouvelles au traitement technique de l'information et ont permis l'avènement de ce que l'on nomme désormais le traitement du signal, dont les application à l'image forment un des domaines aux contours et méthodes particuliers.

Durant une période que l'on peut juger, a posteriori, assez courte, la chaîne d'imagerie électronique fut entièrement analogique, de la caméra vidéo à l'écran cathodique par exemple, la télévision étant un des moteurs des progrès techniques dans le domaine. Peut-être qu'aujourd'hui, à l'époque du numérique roi, les jeunes gens ne se le figurent pas, mais de nombreuses opérations étaient déjà appliquées à ces signaux analogiques qui véhiculaient les images.

Parmi les tous premiers furent les traitements visant à améliorer la qualité visuelle, c'est

à dire à réduire l'effet des perturbations imputables aux dispositifs d'acquisition ou bien ajuster les niveaux de luminosité et contraste d'une prise de vue effectuée dans des conditions difficiles. Bien d'autres, plus complexes, furent aussi maîtrisés comme l'incrustation d'éléments synthétiques ou le codage permettant de réserver la visualisation des images aux détenteurs d'un décodeur adapté. Ce dernier paraîtrait archaïque de nos jours tant son principe était simple : permuter les lignes de chaque image selon une séquence prédéterminée. La capacité de calcul d'un simple téléphone portable actuel serait suffisante pour en décrypter la séquence et décoder les images en temps réel.

Naturellement, la représentation numérique des signaux à de nouveau fait émerger de nouvelles perspectives que l'on ne cerne vraisemblablement que partiellement, pour en vivre les évolutions au jour le jour. L'informatique est le coeur de ces techniques récentes et a déjà permis le développement d'opérations très complexes, quasi irréalisables en analogique, mais aujourd'hui mises à la portée de tout possesseur d'ordinateur personnel. Citons en exemple la segmentation, capacité à distinguer les différentes zones d'une image, ou bien la reconnaissance de formes qui intervient, entre autres, dans l'interprétation de texte manuscrit, ou encore la poursuite (tracking) permettant de suivre l'évolution d'objets en mouvement dans une séquence d'images. Malgré tout, même si certains algorithmes sont capables d'opérations impossibles à la vision humaine, comme par exemple l'extraction d'information dans des images très fortement bruitées, d'autres demeurent très difficiles à automatiser alors que notre cerveau semble les effectuer sans effort, comme la segmentation.

Certains invariants demeurent toutefois, comme le fait que l'image numérisée est naturellement altérée par des *bruits* de nature et intensité variables trouvant leurs origines dans les dispositifs d'acquisition et l'éclairage des scènes. La technologie des capteurs (CMOS), l'accroissement de leur densité en pixels et l'augmentation des fréquences de balayage concourent d'ailleurs à en intensifier les effets, justifiant la recherche de méthodes de réduction de bruit adaptées. De nombreuses solutions ont été proposées et expérimentées au fil des années, toutefois, à ce jour, aucune ne s'est imposée comme universelle par ses propriétés ou son domaine d'application, tant les caractéristiques des images et des perturbations sont variées. Par ailleurs, aucune ne fait sauter le verrou du compromis qualité - vitesse et ainsi les méthodes qui génèrent des résultats de grande qualité ne sont dans la pratique pas utilisables du fait de leur temps de calcul trop long. Paradoxalement, ce type de limitation ne se résout pas automatiquement et systématiquement avec l'accroissement régulier des capacités de calcul des ordinateurs car la résolution des capteurs grandit en suivant une courbe quasi identique. La recherche de performance dans le traitement des images doit donc continuer de diversifier les voies qu'elle emprunte pour faire émerger des structures adaptées. Dans ce contexte, répondant à la demande du grand public pour un rendu toujours plus réaliste des jeux vidéos, les fabricants d'adaptateurs graphiques (cartes graphiques) ont progressivement étendu les capacités de leurs produits pour les doter de moyens de traitement très spécialisés mais pouvant être exécutés à grande vitesse, permettant d'envisager la gestion en temps réel de flux vidéos en haute définition, ce que le processeur central d'un ordinateur personnel ne peut, le plus souvent, pas garantir. Ces cartes graphiques sont ainsi devenues de véritables assistants processeurs graphiques, ou coprocesseur, appelés aujourd'hui GPU pour *graphical processing unit*.

La technologie de fabrication des GPU est identique à celle utilisée pour la fabrication des microprocesseurs classiques qui pilotent nos ordinateurs (CPU) : il s'agit de la photolithographie de motifs sur un substrat de silicium. Les éléments fonctionnels

de base de ces motifs sont des transistors CMOS (Complementary Metal Oxyde semiconductor) mesurant aujourd'hui 22 nm. Pour parvenir à traiter les flux d'image plus rapidement que ne peuvent le faire les CPU, les constructeurs de GPU ont organisé différemment les transistors de sorte à disposer d'un grand nombre de petites unités de calcul, chacune avec une faible capacité de stockage individuelle. Ce faisant, les GPU ne disposent plus de toutes les fonctionnalités de gestion et de contrôle que possèdent les CPU et doivent donc être employés différemment pour tirer parti de cette structure particulière. Pour tenter de comprendre l'organisation d'un GPU actuel, il faut s'imaginer des millions d'exécutants (les fils d'exécution ou threads) regroupés en équipes de travail (les blocs), comportant jusqu'à un millier d'exécutant. Au sein d'une même équipe, les exécutants peuvent communiquer entre eux et échanger des données grâce à un espace de stockage proche et rapide. En revanche, la communication inter équipe est difficile et très lente, associée à un espace de stockage, certes volumineux mais éloigné et dont l'usage s'avère donc très pénalisant. Cette organisation très particulière est naturellement adaptée aux opérations d'affichage, pour lesquelles elle a été conçue, mais considérant les débits permis par ces processeurs graphiques, les chercheurs et développeurs ont très vite voulu profiter de ces performances pour traduire des algorithmes dont les implémentations étaient jusqu'alors trop lentes. Toutefois, l'adaptation à l'architecture des GPU s'est avérée souvent délicate et n'a parfois apporté aucune amélioration des performances.

C'est dans ce cadre que s'inscrivent les travaux présentés ici, axés sur la recherche de méthodes performantes pour le traitement sur GPU d'images numériques bruitées. Nos premiers travaux ont porté sur la segmentation en parallélisant un algorithme existant pour CPU, tout en lui conférant la capacité de traiter des images de plus grande taille (jusqu'à 16 millions de pixels). Nous nous sommes ensuite intéressés à la réduction de bruit et proposé un algorithme original et adaptable à une grande variété de perturbations, du bruit additif gaussien au bruit multiplicatif gamma. La conception de cet algorithme a été guidée par la volonté de fournir un élément fonctionnel performant sur GPU, pas nécessairement optimal au sens de la qualité du traitement, mais permettant une utilisation temps réel tout en apportant une amélioration qualitative par rapport aux filtres rapides simples. Dans le même esprit, nous nous sommes penchés sur l'implémentation du très employé et très étudié filtre médian pour en proposer l'implémentation la plus performante connue à ce jour avec un débit de plus de 1,85 milliards de pixels à la seconde. À cette occasion, nous avons appliqué des principes d'utilisation de la mémoire qui semblent pouvoir être transposables avec succès à d'autres classes d'algorithmes. Nous l'avons ainsi montré pour les filtres de convolutions.

Ces techniques permettent des gains substantiels en terme de vitesse, mais imposent en contrepartie un style de programmation très inhabituel et fastidieux, ôtant parfois toute versatilité aux blocs fonctionnels ainsi conçus. C'est pourquoi enfin, nous avons développé une application en ligne, accessible à tous et permettant de générer simplement le code source des fonctions souhaitées (médiens, convolutions) en sélectionnant les options et valeurs des paramètres adaptés au besoin.

Nous nous attacherons dans la suite à effectuer un survol des techniques de traitement d'images numériques et des principales classes d'algorithmes employés. Ce chapitre sera également l'occasion de définir les notations générales applicables à tous le manuscrit. Dans le chapitre ??, nous présenterons les principaux travaux de recherche en lien avec ceux que nous avons menés et qui seront présentés dans les chapitres ?? et suivants, en commençant par notre contribution à la segmentation orientée régions, suivie

de celles concernant la réduction de bruit sous les formes du filtre contraint par lignes de niveaux, du filtre médian, puis des filtres de convolution.

LES PROCESSEURS GRAPHIQUES (GPU) NVIDIA®

2.1/ POURQUOI ?

S'il fallait en réduire les raisons à une seule, c'est vraisemblablement la concurrence commerciale et la croissance du marché des jeux vidéos qui a poussé les fabricants de cartes graphiques à une innovation permanente qui a donnée naissance aux GPUs. Le rendu graphique dans ce cadre est une opération exigeante en calcul mais intrinsèquement parallèle car chaque pixel est traité individuellement. L'amélioration des résolutions à aussi contribuer à faire évoluer la nature de ces besoins de *parallèle* à *massivement parallèle*, un écran actuel pouvant comporter plus de 2,5 millions de pixels.

La technologie de fabrication étant identique à celle de CPUs, c'est donc au niveau de la répartition des fonctionnalités que les GPUs se distinguent : là où un CPU comporte quelques cœurs de calcul et beaucoup de transistors dédiés à la réalisation de mémoire cache et de contrôle de flux, un GPU présente plusieurs unités comportant chacun une grande quantité de cœurs de calcul ne disposant que de très peu de mémoire cache et de rudimentaires capacités de contrôle, comme l'illustrent les schémas de la figure 2.1.





FIGURE 2.1 – Comparaison des structures d'un cœur de GPU et d'un cœur de CPU (d'après [64]).

Cette spécialisation des circuit GPUs a permis d'en améliorer les performances brutes beaucoup plus rapidement que pour les CPUs, au fil des évolutions de la technologie. Il en est allé de même pour les débits mémoire théoriques. Les graphiques de la figure 2.2 comparent les rythmes de ces évolutions pour les GPU Nvidia® et pour les CPU Intel®.

Les problèmes requérant les capacités de calcul spécifiques des GPU ne sont cependant pas limités aux questions de rendu graphique, aussi les scientifiques ont-ils très vite cherché à tirer parti de la puissance de calcul croissante des GPUs pour traiter d'autres

types de problèmes, faisant sens à l'acronyme GPGPU.



(a) Nombre maximum théorique d'opérations en virgule flottante par seconde en fonction de l'année et de l'architecture. (b) Bande passante théorique maximale des diverses architectures.

FIGURE 2.2 – Comparaison des performances des GPUs Nvidia et des CPUs Intel (d'après [64]).

Malgré des caractéristiques prometteuses, les GPGPUs n'ont pas immédiatement déclenché une vague d'expérimentations scientifiques dans des domaines variés, l'essentiel des travaux étant liés à la construction et la visualisation des données issues de l'instrumentation d'imagerie médicale.

C'est la parution de l'extension de langage CUDA qui a réellement démocratisé l'emploi des GPGPUs et favorisé l'émergence de travaux variés. CUDA est une extension de haut niveau du langage C permettant d'écrire facilement des fonctions s'exécutant en parallèle sur le GPU, que l'on appelle des *kernels*. L'extension CUDA permet également de gérer de manière transparente les changements d'échelle du parallélisme d'une architecture à une autre ou tout simplement les dimensions de la grille de calcul. Ces possibilités rendent l'accès facile à la programmation GPU.

2.2/ COMMENT ?

2.2.1/ LE MATÉRIEL

Pour bien tirer parti des capacités des GPUs, il est important d'en comprendre l'organisation matérielle. Nous limiterons cette présentation à l'architecture dite *Fermi* à laquelle appartient le GPU C2070 qui a servi à l'essentiel de nos expérimentations et dont la constitution est détaillée par les diagrammes de la figure 2.3.

Le circuit se divise en 4 groupes de processeurs de flux (les SMs), chacun groupe en comprenant 3 ou 4 pour un total de 14 SMs. Chaque SM héberge à son tour 32 cœurs de calcul (les SPs). Les threads sont exécutés par paquets de 2×16 , soit 32 (les warps) sur les 32 cœurs de calcul.

Les ressources mémoire sont de plusieurs nature tant du point de vue volume disponible, que portée ou bien débit. Le tableau 2.1 en synthétise les caractéristiques. Il faut retenir que les registres sont peu nombreux, embarqués sur le circuit (on-chip) et présentent

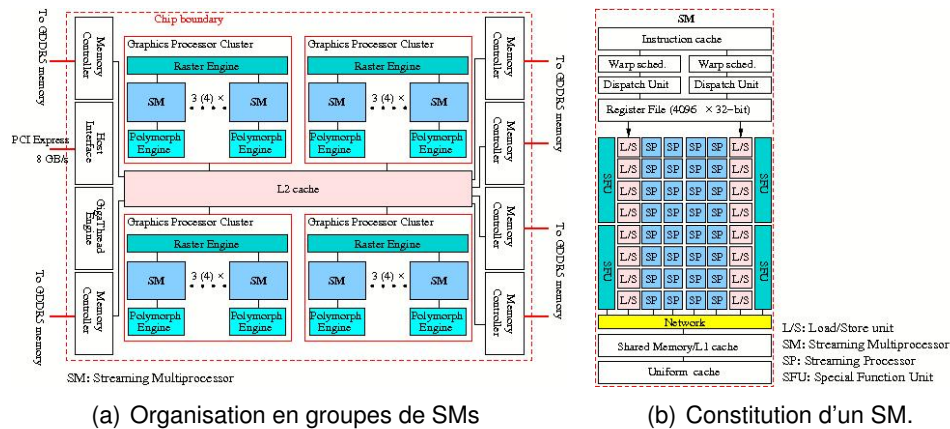


FIGURE 2.3 – Organisation des GPU d'architecture Fermi, comme le C2070 (d'après www.hpcresearch.nl).

les meilleures performances alors que la mémoire principale, dite globale, est externe au circuit (off-chip), de grande capacité mais présente des latences importantes de plusieurs centaines de cycles d'horloge.

Une petite quantité de mémoire on-chip est présente sur chaque SM et permet la communication entre les threads s'exécutant sur ce SM. Cette mémoire est appelée *mémoire partagée* et permet des débits bien supérieurs à la mémoire globale.

	Propriétés				
	Emplacement (on/off-chip)	Portée	Latence (cycles)	débit (Go/s)	Taille (octets)
Registres	on-chip	thread	1	8000	32K par SM
Partagée	on-chip	bloc	38	1300	48K
Constante	off-chip	grille	370/46/140	8000	64K
Texture	off-chip	grille	500/260/372	...	6G
Locale	off-chip	thread	550	...	512K
Globale	off-chip	grille	580/80/350	144	6G

TABLE 2.1 – Caractéristiques des différents types de mémoire disponibles sur le GPU. Pour les mémoires cachées, les latences sont données selon l'accès *sans-cache*/L1/L2/. Les mesures ont été obtenues à l'aide des microprogrammes de test de [94].

2.2.2/ LE LOGICIEL

Dans le modèle CUDA, chaque *kernel* est exécuté par un certain nombre de threads. Chaque thread possède un identifiant unique, accessible à l'intérieur du kernel, ce qui permet d'en individualiser le traitement. L'ensemble des threads est organisé en plusieurs blocs indépendants, puis ces blocs en grille. Pour faciliter la représentation de modèles variés, les blocs de threads ainsi que la grille de blocs peuvent être décrits par des tableaux à une, deux ou trois dimensions. Le nombre total de threads appartenant à un même bloc est cependant limité, selon la version de GPU, à 512 ou 1024. Le diagramme

de la figure 2.4 illustre l'organisation d'une grille de calcul à 2 dimensions et des ses blocs, également à 2 dimensions, situation qui correspond à la majorité des modèles d'exécution de nos *kernels* de traitement d'image.




FIGURE 2.4 – Représentation d'une grille de calcul en 2D et des blocs de threads, à 2 dimensions, qui la composent.

Au sein d'un même bloc, les threads peuvent communiquer efficacement grâce à la mémoire partagée, rapide et présentant une faible latence. La communication inter-blocs passe nécessairement par la mémoire globale dont l'emploi est pénalisant.

L'emploi de la mémoire partagée n'est cependant pas transparent comme peut l'être un cache de niveau 1 (L1) et les motifs d'accès doivent respecter un certain nombre de conditions pour en obtenir les performances attendues. Le non respect de ces contraintes conduit le plus souvent à un bout programme dont l'exécution s'avère plus lente que son équivalent CPU.

2.2.3/ L'OCCUPANCY

Pour atteindre les meilleures performances possible, le fabricant Nvidia recommande d'avoir toujours suffisamment de threads dans chaque bloc et de blocs dans la grille et ce, pour masquer les latences des accès aux mémoires, mais aussi celles des instructions arithmétiques. Il définit un indice nommé *occupancy*, que l'on pourrait franciser par *charge* qui représente, à chaque instant, le rapport du nombre de blocs de threads actifs par SM sur le nombre maximum de threads actifs par SM (1536 sur C2070).

La valeur de l'*occupancy* peut se trouver limitée par un usage trop intensif des ressources mémoire par les threads (registres, mémoire partagée) ou bien par une grille de calcul mal dimensionnée. L'ensemble des paramètres intervenant dans le calcul l'*occupancy* est pris en compte dans une feuille de tableur (l'*occupancy calculator*) fournie par Nvidia pour aider les développeurs à bien employer les ressources des divers modèles de GPU.

Les limitations de l'*occupancy* ont pour origine :

1. **l'usage des registres.** Si chaque thread utilise le maximum de registres possible ($63 + 1 = 64$), le bloc de thread affecté au SM ne peut donc activer simultanément que $32K/64 = 512$ threads, soit une *occupancy* de $512/1536 = 0.33$.

2. **l'usage de la mémoire partagée.** L'architecture Fermi permet de choisir la répartition entre cache L1 et mémoire partagée, soit 16K/48K, soit 48K/16K. En configuration 48K de mémoire partagée, si chaque thread en emploie 48 octets, le GPU ne peut activer que $48K/48 = 1024$ threads, soit une *occupancy* de $1024/1536 = 0.66$.
3. **la taille des blocs.** Un SM ne pouvant activer que 8 blocs simultanément, la taille des blocs limite donc potentiellement l'*occupancy*. Si on exécute un *kernel* sur une grille de calcul dont les blocs ont le minimum de 32 threads, les 8 blocs actifs représenteront alors 256 threads, soit une *occupancy* de $256/1536 = 0.16$.

Nous verrons que cette notion d'*occupancy* si elle conserve du sens, peut toutefois être remise en question en optimisant d'autres aspects permettant d'arriver à une réduction de l'effet des latences, comme le parallélisme d'instructions ou l'augmentation du volume des transactions. Ces techniques ainsi que l'emploi fin des mémoires du GPU permettent d'obtenir des performances élevées sur GPU, parfois inenvisageables en suivant les prescriptions du constructeur.

LE TRAITEMENT DES IMAGES BRUITÉES

L'étendue des techniques applicables aux images numériques est aujourd'hui si vaste qu'il serait illusoire de chercher à les décrire ici. Ce chapitre présente plus spécifiquement les algorithmes utilisés en présence d'images (fortement) bruitées. Le bruit rend potentiellement délicate l'extraction des informations utiles contenues dans les images perturbées ou en complique l'interprétation, qu'elle soit automatique ou confiée à la vision humaine. L'intuition nous incite donc à chercher des méthodes efficaces de pré-traitement pour réduire la puissance du bruit afin de permettre aux traitements de plus haut niveau comme la segmentation, d'opérer ensuite dans de meilleures conditions.

Toutefois, il faut également considérer que les opérations préalables de réduction de bruit apportent des modifications statistiques aux images et influent donc potentiellement sur les caractéristiques que l'on cherche à mettre en évidence grâce au traitement principal. En ce sens, il peut-être préférable de chercher à employer des algorithmes de haut niveau travaillant directement sur les images bruitées pour minimiser les effets des altérations apportées par les filtres débruiteurs et conserver toute l'information contenue dans les images perturbées.

Enfin, toute opération aussi basique soit elle, prend un certain temps qui réduit potentiellement celui disponible pour le traitement de haut niveau. Lorsque les images à analyser sont de grande taille, procéder à un débruitage préalable peut s'avérer incompatible avec les contraintes de débit et les temps requis par le traitement de haut niveau.

Les images auxquelles nous nous intéressons sont généralement les images numériques allant des images naturelles telles que définies par Caselles [15] aux images d'amplitude issues de l'imagerie radar à ouverture synthétique (ROS ou en anglais SAR) [28], de l'imagerie médicale à ultrasons (échographie) ou encore biologique dans le cas de la microscopie électronique. Ces dispositifs d'acquisition sont naturellement, et par essence, générateurs de bruits divers, inhérents aux technologies mises en œuvre au sein de ces systèmes et qui viennent dégrader l'image idéale de la scène que l'on cherche à représenter ou analyser. On sait aujourd'hui caractériser de manière assez précise ces bruits et la section 3.2 en détaille les origines physiques ainsi que les propriétés statistiques qui en découlent. On peut doré et déjà avancer que la connaissance de l'origine d'une image et donc des propriétés des bruits associés qui en corrompent les informations, est un atout permettant de concevoir des techniques de filtrage adaptées à chaque situation. Toutefois, la recherche d'un filtre universel, bien qu'encore illusoire, n'est pas abandonnée, tant les besoins sont nombreux, divers et souvent complexes.

3.1/ MODÈLE D'IMAGE BRUITÉE

On considère qu'une image observée, de largeur L pixels et de hauteur H pixels, est un ensemble de $N = HL$ observations sur un domaine Ω à deux dimensions ($\Omega \subset \mathbb{Z}^2$). À chaque élément de Ω , aussi appelé *pixel*, est associé un indice unique $k \in \llbracket 1; N \rrbracket$, une position $x_k = (i, j)_k \in \Omega$ et une valeur observée $v_k = v(i, j)_k$. La valeur observée peut, selon les cas, être de dimension 1 pour les images représentées en niveaux de gris ou de dimension 3 pour les images couleur représentées au format RVB. Les dimensions supérieures, pour la représentation des images hyperspectrales n'est pas abordé. L'image observée peut ainsi être considérée comme un vecteur à N éléments $\bar{v} = (v_k)_{k \in \llbracket 1; N \rrbracket}$. Les divers traitements appliqués aux images observées ont souvent pour but d'accéder aux informations contenues dans une image sous-jacente, débarrassée de toute perturbation, dont nous faisons l'hypothèse qu'elle partage le même support Ω et que nous notons \bar{u} . L'estimation de \bar{u} réalisée par ces traitements est notée $\widehat{\bar{u}} = (\widehat{u}_k)_{k \in \llbracket 1; N \rrbracket}$. Le lien entre \bar{u} et \bar{v} peut être exprimé généralement par la relation $\bar{v} = \bar{u} + \sigma \epsilon$, où $\epsilon \in \mathbb{R}^N$ représente le modèle de perturbation appliquée à \bar{u} et σ représente la puissance de cette perturbation qui a mené à l'observation de \bar{v} . Dans le cas général, ϵ dépend de \bar{u} et est caractérisé par la densité de probabilité (PDF pour probability density function) $p(v|u)$.

3.2/ MODÈLES DE BRUIT

3.2.1/ LE BRUIT GAUSSIEN

Le bruit gaussien est historiquement le plus étudié et celui auquel sont dédiées le plus de techniques de débruitage. La génération des images numériques au travers les capteurs CMOS et CCD est le siège de nombreuses perturbations dues à la technologie de fabrication et à la nature du rayonnement dont ils mesurent l'intensité en différents zones de leur surface, appelées *photosites* [61, 84]. On distingue en particulier les bruits suivants selon leur origine physique :

- la non uniformité de réponse des photosites.
- le bruit de photon
- le bruit de courant d'obscurité
- le bruit de lecture
- le bruit de non uniformité d'amplification des gains des photosites.

On trouve des descriptions détaillées des mécanismes concourant à la génération de ces bruits, entre autres dans [44] et [2]. Dans un certain intervalle usuel d'intensité lumineuse, il est toutefois admis que l'ensemble des ces perturbations peut être représenté par un seul bruit blanc gaussien, de type *additif* (AWGN), dont la densité de probabilité suit une loi normale de moyenne nulle et de variance σ^2 . On a alors l'expression suivante, où $\sigma > 0$

$$p(v|u) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(v-u)^2}{2\sigma^2}}$$

3.2.2/ LE SPECKLE

En imagerie radar, sonar ou médicale, les surfaces que l'on veut observer sont "éclairées" par des sources cohérentes. Les propriétés locales de ces surfaces sont le siège de

réflexions multiples qui interfèrent entre elles pour générer un bruit de tavelures, ou speckle, dont l'intensité dépend de l'information contenue dans le signal observé.

Le speckle est ainsi un bruit de type *multiplicatif* qui confère aux observations une très grande variance qui peut-être réduite en moyennant plusieurs observations, ou vues, de la même scène. Si L est le nombre de vues, le speckle est traditionnellement modélisé par la PDF suivante :

$$p(v | u) = \frac{L^2 v^{L-1} e^{-L \frac{v}{u}}}{\Gamma(L) u^L}$$

L'espérance vaut $E[v] = u$ et la variance $\sigma^2 = \frac{u^2}{L}$ est effectivement inversement proportionnelle à L , mais pour le cas mono vue où $L = 1$, la variance vaut u^2 , soit un écart type du signal v égal à sa moyenne.

3.2.3/ LE BRUIT "SEL ET POIVRE"

Le bruit *sel et poivre*, ou bruit *impulsionnel* trouve son origine dans les pixels défectueux des capteurs ou dans les erreurs de transmission. Il tire son nom de l'aspect visuel de la dégradation qu'il produit : des pixels noirs et blancs répartis dans l'image. Le bruit impulsionnel se caractérise par la probabilité P d'un pixel d'être corrompu. La PDF peut alors être exprimée par parties comme suit, pour le cas d'images en 256 niveaux de gris (8 bits) :

$$p(v | u) = \begin{cases} \frac{P}{2} + (1 - P) & \text{si } v = 0 \text{ et } u = 0 \\ \frac{P}{2} + (1 - P) & \text{si } v = 255 \text{ et } u = 255 \\ \frac{P}{2} & \text{si } v = 0 \text{ et } u \neq 0 \\ \frac{P}{2} & \text{si } v = 255 \text{ et } u \neq 255 \\ (1 - P) & \text{si } v = u \text{ et } u \notin \{0, 255\} \\ 0 & \text{sinon} \end{cases}$$

3.2.4/ LE BRUIT DE POISSON

Aussi appelé *bruit de grenaille* (shot noise), ce type de bruit est inhérent aux dispositifs de détection des photons. Il devient prépondérant dans des conditions de faible éclairément, lorsque la variabilité naturelle du nombre de photons reçus par un photosite par intervalle d'intégration influe sur les propriétés statistiques du signal. Le bruit de grenaille est de type multiplicatif et suit une loi de Poisson. La PDF peut s'écrire comme suit :

$$p(v | u) = e^{-\frac{u}{v}} \frac{u^v}{v!}$$

3.3/ LES TECHNIQUES DE RÉDUCTION DE BRUIT

La très grande majorité des algorithmes de réduction de bruit fait l'hypothèse que la perturbation est de type gaussien, même si le développement des systèmes d'imagerie radar et médicale a favorisé l'étude des bruits multiplicatifs du type *speckle* ou *Poisson*.




FIGURE 3.1 – Images 256×256 en niveau de gris 8 bits utilisées pour l'illustration des propriétés des filtres. a) l'image de référence non bruitée. b) l'image corrompue par un bruit gaussien d'écart type $\sigma = 25$. c) l'image corrompue par un bruit impulsionnel à 25%.

Un très grand nombre de travaux proposant des méthodes de réduction de ces bruits ont été menés, ainsi que beaucoup d'états de l'art et d'études comparatives de ces diverses techniques, que nous n'avons pas l'ambition d'égaliser.

Nous nous focaliserons sur les techniques en lien avec les travaux que nous avons menés et qui ont donné lieu à des implémentations efficaces susceptibles de fournir des éléments opérationnels rapides pour le pré-traitement des images.

La figure 3.1 montre une image de synthèse issue de la base de test COIL [63], supposée sans bruit et qui sera considérée comme référence, ainsi que deux versions bruitées, respectivement avec un bruit gaussien d'écart type 25 et un bruit impulsionnel affectant 25% des pixels. L'indice de qualité le plus employé pour mesurer la similarité entre deux images est le PSNR (pour Peak Signal to Noise Ratio). Il est exprimé en décibels (dB) et se calcule en appliquant la formule

$$PSNR = 10 \log_{10} \left(\frac{D^2}{\frac{1}{N} \sum_{k < N} (v_k - u_k)^2} \right)$$

si l'on cherche à évaluer le PSNR de l'image observée \bar{v} par rapport à l'image de référence \bar{u} . Le nombre D représente la dynamique maximale des images, e.g 255 pour des images en niveaux de gris codés sur 8 bits.

Cet indicateur seul est cependant insuffisant pour caractériser convenablement la qualité de débruitage d'un filtre, mesure hautement subjective. Un indice global de similarité structurelle (MSSIM pour Mean Structural Similarity Index) a été proposé par Wang *et al.* [93] et permet, en conjonction avec le PSNR, de garantir une mesure de qualité plus en rapport avec la perception visuelle. Le MSSIM prend ses valeurs dans l'intervalle $[0; 1]$ avec une similarité d'autant plus grande que la valeur est proche de 1.




FIGURE 3.2 – Filtrage par convolution.

3.3.1/ LES OPÉRATEURS DE BASE

3.3.1.1/ LE FILTRE DE CONVOLUTION

L'opération la plus employée dans les procédés de traitement d'image est sans doute la convolution. Selon les valeurs affectées aux coefficients du masque, le filtrage par convolution permet de réaliser bon nombre de traitements comme la réduction de bruit par moyennage ou noyau gaussien ou encore la détection de contours. Si la fonction définissant le masque de convolution est notée h , l'expression générale de la valeur estimée de pixel de coordonnées (i, j) est donnée par

$$\widehat{u}(x, y) = (\bar{v} * h) = \sum_{(i < H)} \sum_{(j < L)} v(x - j, y - i)h(j, i) \tag{3.1}$$

Dans les applications les plus courantes, h est à support borné et de forme carrée et l'on parle alors de la taille du masque pour évoquer la dimension du support. La figure 3.2 présente les résultats de la convolution par deux masques débruiteurs *moyenneurs* h_3 et h_5 de taille différentes, appliqués à l'image corrompue par un bruit gaussien : on voit la diminution des fluctuations mais aussi le flou apporté et qui rend les contours d'autant moins définis que la taille du masque est grande. La troisième image montre l'effet d'un masque gaussien h_{g3} . Les matrices définissant les masques sont les suivantes :

$$h_3 = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}, h_{25} = \frac{1}{25} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}, h_{dx} = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

3.3.1.2/ LE FILTRE MÉDIAN

Le filtrage médian [86] est également une opération très employée en prétraitement pour sa simplicité et ses propriétés de préservation des contours alliées à une capacité de réduction de bruit gaussien importante. La valeur du niveau de gris de chaque pixel est remplacée par la médiane des niveaux de gris des pixels voisins. Un des intérêts de ce




FIGURE 3.3 – Réduction du bruit impulsionnel par filtre médian.

filtre réside dans le fait que la valeur filtrée est une des valeurs du voisinage, contrairement à ce qui se produit lors d'une convolution. Un autre est de bien filtrer les valeurs extrêmes et par conséquent de trouver naturellement son application dans la réduction du bruit impulsionnel. Toutefois, la non-linéarité de cette technique et sa complexité n'en ont pas fait un filtre très utilisé jusqu'à ce que des implémentations efficaces soient proposées, en particulier le filtre à temps de calcul "constant" décrit par Perreault et Hebert [69]. Il est à noter que le filtrage médian est souvent appliqué en plusieurs passes de voisinage restreint. La figure 3.3 montre la réduction de bruit impulsionnel obtenu grâce au filtre médian, dans trois conditions distinctes : median 3×3 en une ou deux passes, puis médian 5×5.

3.3.1.3/ LE FILTRE BILATÉRAL

Le filtre bilatéral [85] est une composition d'opérations que l'on peut voir comme un filtre de convolution dont les coefficients ne dépendraient pas uniquement de la position du pixel courant par rapport au pixel central, mais également de la différence de leurs intensités (cas des images en niveaux de gris). Si l'on note Ω_k le voisinage du pixel d'indice k , l'expression générale du niveau de gris estimé est donnée par

$$\hat{u}_k = \frac{\sum_{p \in \Omega_k} (F_S(x_p, x_k) F_I(v_p, v_k) v_p)}{\sum_{p \in \Omega_k} (F_S(x_p, x_k) F_I(v_p, v_k))}$$

où F_S et F_I sont les fonctions de pondération spatiale et d'intensité. Classiquement, F_S et F_I sont des gaussiennes de moyennes nulles et d'écart type σ_S et σ_I . Ce filtre se prête également bien à une utilisation en plusieurs passes sans flouter les contours. Des approximations séparables du filtre bilatéral, comme celle proposée dans [70], permettent d'obtenir des vitesses d'exécution plus élevées que les versions standard. Une variante à temps de calcul constant a même été proposée en 2008 par Porikli [71]. Ce filtre permet un bon niveau de réduction de bruit gaussien, mais au prix d'un nombre de paramètres plus élevé à régler, ce qu'illustre la figure 3.4 où le filtrage de la même image a été réalisé avec 9 combinaisons de σ_S et σ_I .

Il existe beaucoup de variantes d'algorithmes basés sur des moyennes ou médianes locales effectuées sur des voisinages de formes diverses, variables et/ou adaptatives afin




FIGURE 3.4 – Réduction de bruit gaussien par filtrage bilatéral de voisinage 5×5 . σ_s et σ_I sont les écarts type des fonctions gaussiennes de pondération spatiale et d'intensité.




FIGURE 3.5 – Filtrage par décomposition en ondelettes et seuillage dur des coefficients inférieurs au seuil T .

de sélectionner le plus finement possible les pixels pris en compte dans le calcul de la valeur filtrée. Le principal défaut de ces techniques est de générer des aplats dans les zones homogènes et des marches d'escalier dans les zones de transition douce (staircase effect), ces dernières pouvant être considérablement atténuées comme il a été montré dans [14]. L'un de ces algorithmes tend à utiliser une portion de la ligne de niveau de chaque pixel comme voisinage pour le moyennage. Cette technique a été présentée dans [9] et employée pour réduire le bruit de speckle. Nous y reviendrons en détail dans le chapitre ??.

3.3.1.4/ LES ALGORITHMES DE FILTRAGE PAR DICTIONNAIRE

Ces algorithmes font l'hypothèse qu'il est possible de décrire l'image à débruiter en utilisant une base de fonctions permettant de décomposer l'image en une combinaison linéaire des éléments de cette base. Les bases les plus employées sont les ondelettes [60, 31] ainsi que les fonctions sinusoïdales (DCT [21, 82]). Les éléments de la base peuvent être prédéterminés ou bien calculés à partir des données de l'image, par exemple en s'appuyant sur une analyse en composantes principales ou après apprentissage [33]. Le principe du débruitage est de considérer que le bruit est décorrélé des fonctions de la base et donc représenté par les petits coefficients de la décomposition, que l'on peut annuler. Diverses politiques de seuillage peuvent alors être appliquées selon le type d'image et le modèle de bruit ayant chacune ses propres avantages et inconvénients. L'intérêt principal de ces méthodes est de bien restituer les transitions rapides (grande énergie), mais elles génèrent en revanche des artefacts dus aux possibles grands coefficients de bruit. La figure 3.5 illustre cela en montrant le résultat du débruitage obtenu par décomposition en ondelettes et seuillage "dur". Certains algorithmes récents, en particulier ceux utilisant une base d'ondelettes adaptative, comme dans [33] sont proches, en terme de qualité, de l'état de l'art du domaine, avec souvent un avantage lié à des vitesses d'exécution assez rapides.

3.3.2/ LES ALGORITHMES DE FILTRAGE PAR PATCHES

Les techniques de réduction de bruit les plus efficaces sont aujourd'hui celles qui reposent sur les propriétés d'auto-similarité des images, on les appelle aussi les tech-




FIGURE 3.6 – Filtrage par NL-means pour différentes combinaisons des paramètres de similarité f et de non localité t .




FIGURE 3.7 – Filtrage par BM3D, PSNR=29.3 dB MSSIM=0.41

niques par patches. L'idée principale est, comme pour les techniques classiques à base de voisinage, de rechercher un ensemble de pixels pertinents et comparables afin d'en faire une moyenne. Cependant, dans le cas des techniques à patches, la recherche de cet ensemble ne se limite pas à un voisinage du pixel central, mais fait l'hypothèse qu'il existe des zones semblables au voisinage du pixel central, réparties dans l'image et pas nécessairement immédiatement contigües. Le moyennage s'effectue alors sur l'ensemble de ces zones identifiées. L'algorithme des moyennes non locales (NL-means, [13]) fut parmi les premiers de cette lignée à être proposé et bien qu'ayant représenté un progrès notable dans la qualité de débruitage, fut rapidement suivi, en particulier par le BM3D et ses variantes qui représentent actuellement l'état de l'art en terme de qualité de débruitage [29, 30]. Les différences entre ces algorithmes résident essentiellement dans la méthode de recherche et d'identification des patches similaires, incluant la possibilité de forme et taille variables. Une telle recherche est d'autant plus coûteuse en temps de calcul qu'elle est effectuée sur une zone étendue autour du patch central et cela représente le principal inconvénient de ces techniques qui peuvent présenter des temps d'exécution prohibitifs dans l'optique d'un traitement en temps réel. La figure 3.6 montre des résultats de débruitage obtenus par la méthode des NL-means avec plusieurs combinaisons des paramètres de similarité des patches et de non localité du voisinage, notés f et t . La figure 3.7 montre quant-à elle le résultat du débruitage par BM3D. Les points forts de ces deux techniques sont, comme on le voit, la qualité du débruitage avec pour l'implémentation BM3D l'avantage de ne nécessiter aucun réglage de paramètres.

3.4/ LES IMPLÉMENTATIONS GPU DES ALGORITHMES DE FILTRAGE

Le fabricant de processeurs graphiques Nvidia, seul type d'équipements dont nous disposons, fournit des implémentations performantes de certains prétraitements et algorithmes de filtrage. C'est le cas des transformées de fourrier (FFT, DCT), qui sont par exemple utilisées dans l'implémentation d'un algorithme d'*inpainting* [52].

3.4.1/ LE FILTRAGE PAR CONVOLUTION

C'est aussi vrai pour l'opération de convolution qui a fait l'objet d'une étude et d'une optimisation poussées pour déterminer la combinaison de solutions apportant la plus grande vitesse d'exécution [80]. L'étude a testé 16 versions distinctes, chacune présentant une optimisation particulière quant-à l'organisation de la grille de calcul, aux types de transferts entre l'hôte et le GPU ainsi qu'au types de mémoire employé pour le calcul sur le GPU.

Les résultats montrent que l'emploi de texture comme mémoire principale pour le stockage des images à traiter apporte un gain d'environ 50% par rapport à l'utilisation de la mémoire globale. Par ailleurs, les transactions par paquets de 128 bits apportent également une amélioration sensible, ainsi que l'emploi de la mémoire partagée comme zone de travail pour le calcul des valeurs de sortie. Le traitement de référence effectué pour les mesures est la convolution générique (non séparable) d'une image 8 bits de 2048×2048 pixels par un masque de convolution de 5×5 pixels, expression que l'on raccourcira déronavant en *convolution 5×5*.

Le meilleur résultat obtenu dans les conditions détaillées précédemment, sur architecture GT200 (carte GTX280) est de 1.4 ms pour le calcul, ce qui réalise un débit global de 945 MP/s lorsque l'on prend en compte les temps de transfert aller et retour des images (1.5 ms d'après nos mesures). Nous continuerons d'utiliser cette mesure de débit en *Pixels par seconde* pour toutes les évaluations à venir; elle permet en particulier de fournir des valeurs de performance indépendantes de la taille des images soumises au traitement.

3.4.2/ LE FILTRE MÉDIAN

On connaît peu de versions GPU du filtre médian, peut-être en raison des implémentations CPU performantes et génériques que l'on a déjà évoquées (voir par exemple [69]) et dont le portage sur GPU ne laisse pas entrevoir de potentiel, ou bien reste à inventer. Néanmoins, une bibliothèque commerciale (LibJacket et ArrayFire) en propose une implémentation GPU dont nous avons pu mesurer les performances pour un masque de 3×3 et qui est également prise comme référence par Sanchez *et al.* pour évaluer les performances de leur propre implémentation appelée PCMF [75].

Sur architecture GT200 (GTX260), les performances maximales de ces deux versions sont obtenues pour un masque de 3×3 pixels avec respectivement 175 MP/s pour libJacket et 60 MP/s pour PCMF. Une précédente implémentation avait été réalisée, basée sur l'algorithme BVM décrit dans [49]. Elle prouve son efficacité dans l'élimination des

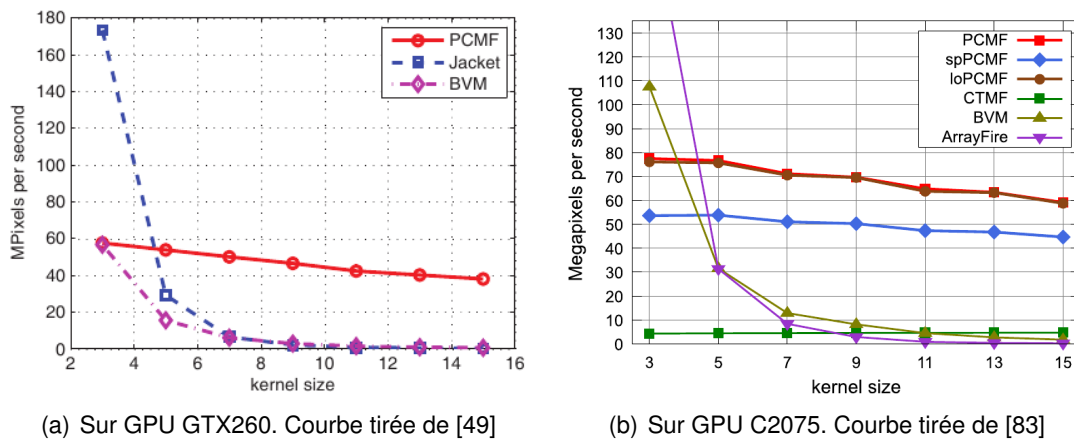


FIGURE 3.8 – Performances relatives des filtres médians implémentés sur GPU dans libJacket/ArrayFire, PCMF et BVM et exécutés sur deux modèle de générations différentes.

artefacts générés par les dispositifs d'imagerie médicale magnétique en 3D [20], mais ne permet pas d'exploiter véritablement le parallélisme des GPU en filtrage d'image en 2D.

La figure 3.8(a), tirée de [49], compare ces trois implémentations et montre que le débit permis par la libJacket décroît très vite avec la taille du masque pour passer à 30 MP/s dès la taille 5×5 , alors que le PCMF décroît linéairement jusqu'à la taille 11×11 où il permet encore de traiter quelque 40 MP/s. Ceci s'explique simplement par le fait que libJacket utilise un tri simple pour la sélection de la valeur médiane alors que le PCMF exploite les propriétés des histogrammes cumulés et n'est ainsi que très peu dépendant de la taille du masque.

Plus récemment, Sanchez *et al.* ont actualisé dans [83] leurs mesures sur architecture Fermi (GPU C2075) en comparant leur PCMF à la version ré-écrite en C de libJacket, nommée ArrayFire. Les courbes sont celles de la figure 3.8(b), où l'on constate que les variations selon la taille du masque demeurent comparables, avec toutefois des valeurs de débit augmentées, avec près de 185 MP/s pour ArrayFire et 82 MP/s pour PCMF.

Parallèlement, on trouve aussi des implémentations de filtre médian dans des traitements plus complexes comme dans [5] où les auteurs décrivent la plus récente évolution de leur technique itérative de réduction de bruit impulsif, sans qu'il soit possible d'évaluer le débit du médian seul.

Il faut noter enfin que certains codes sont plus performants sur l'ancienne architecture GT200/Tesla que sur la plus récente Fermi ; c'est le cas pour l'implémentation du médian incluse dans la bibliothèque ArrayFire et nous reviendrons sur les raisons de cette perte de performances constatée au passage à une architecture plus récente dans le chapitre consacré à notre implémentation du filtre médian.

3.4.3/ LE FILTRE BILATÉRAL

Le filtre bilatéral a été plus abordé et un certain nombre de publications font état d'implémentations rapides. Une implémentation à temps constant en est proposée par Yang *et al.* [97] et s'exécute entre 3.7 ms et 15 ms pour une image de 1 MP. Cela ne constitue pas une référence de vitesse pour les masques de petite taille, mais de-




FIGURE 3.9 – Illustration pré-chargement en mémoire partagée mise en œuvre dans [99] pour l’implémentation, entre autres, du filtre bilatéral. a) en vert le bloc de threads associé aux pixels centraux. b-e) les blocs de pixels successivement pré-chargés en mémoire partagée. f) la configuration finale de la ROI en mémoire partagée.

vient compétitif pour des masque de grande taille (plus de 400 pixels dans le voisinage). Une autre plus classique, employée dans la génération des images médicales tomographiques, annonce 16 ms pour un masque de 11×11 sur une image de 0.25 MP. Il demeure souvent difficile de comparer les implémentations sans disposer des codes sources, en raison de conditions de test très variables, en particulier en ce qui concerne le modèle de GPU et la taille du masque. Ceci étant précisé, on peut prendre comme première référence la version proposée par Nvidia dans le SDK CUDA et nommée “ImageDenoising”. Elle permet d’exécuter sur GPU GTX480 un filtre bilatéral 7×7 sur une image, déjà en mémoire GPU, de 1 MPixels en 0.411 ms, pour un débit global de 133 MP/s.

Dans [99], les auteurs présentent un cadre général pour optimiser l’accès aux données par les différents kernels en utilisant la mémoire partagée pour les threads d’un même bloc. Le principe est de pré-charger les valeurs utiles au bloc de threads dans la mémoire partagée, cela comprend les valeurs (niveaux de gris) des pixels associés aux threads ainsi que le halo correspondant aux voisinages des pixels de la bande périphérique. On appelle communément cet ensemble la *region of interest* ou ROI. La figure 3.9 illustre la mise en œuvre de cette technique en montrant comment les threads d’un bloc se répartissent les pré-chargements en mémoire partagée des valeurs des pixels de la ROI. La géométrie des blocs de threads est ici choisie carrée, mais elle s’applique aisément à d’autres proportions comme nous le verrons plus loin. Les limites de cette méthode sont

- la taille de la mémoire partagée qui doit pouvoir stocker l’ensemble des valeurs des pixels de la ROI, ce qui peut imposer une limite sur la taille des blocs de threads.
- l’étendue du voisinage qui ne peut être pré-chargé de cette façon (4 pixels par thread) que si la surface de la ROI demeure inférieure à 4 fois le nombre de thread par bloc.

Cette recette est ensuite appliquée dans l’implémentation d’un filtre bilatéral et d’un filtre à moyennes non locales (NL-means). Concernant le filtre bilatéral, ils pré-calculent aussi les coefficients de la pondération spatiale, alors que ceux de la pondération d’intensité

resent calculés à la volée. Ces deux optimisations permettent un gain de 20% sur le temps de calcul du filtre bilatéral pour arriver à 0.326 ms dans les mêmes conditions que ci-dessus. Toutefois, le débit global ne gagne que très peu (132 MP/s) en raison de la prépondérance des temps de transfert annoncés à 7.5 ms pour l'image de 1 MP.

Ce travail d'optimisation ne perd toutefois pas son intérêt, en ce sens où si le filtre fait partie d'une chaîne de traitement entièrement exécutée par le GPU, le transfert des données n'a besoin d'être effectué qu'une seule fois en tout début et en toute fin de traitement.

Enfin, l'implémentation qui semble à ce jour la plus performante s'attache à réduire les redondances de calculs et parvient à filtrer une image de 9 MP avec un masque de 21×21 en seulement 200 ms, soit un débit de 47 MP/s hors transferts.

3.4.4/ LES FILTRES PAR PATCHES

Intuitivement, les algorithmes à base de patches paraissent moins adaptés au parallélisme des GPU, du fait de la nécessité d'accéder à un voisinage étendu autour de chaque pixel. On recense malgré tout quelques implémentations dont celle présente dans le SDK CUDA qui fait cependant l'hypothèse que les coefficients de pondération spatiale sont localement constants. Dans [67], le modèle de bruit employé vise une adaptation aux images échographiques présentant du bruit proche du speckle. Dans cette implémentation, aucune approximation des coefficients n'est faite, mais la taille maximale du patch est limitée par la quantité de mémoire partagée disponible pour chaque bloc de threads. Une version plus récente implémente exactement l'algorithme original [42] en proposant des optimisations algorithmiques exploitant la symétrie des coefficients spatiaux ainsi que l'interprétation du calcul de la similarité comme une convolution séparable, opération aisément parallélisable sur GPU, comme nous le détaillerons plus loin. Les auteurs parviennent ainsi à filtrer des séquences vidéo couleur de dimension 720×480 à plus de 30 fps en améliorant le PSNR de 16 dB (la séquence bruitée présentant un PSNR de 20 dB).

3.5/ LES TECHNIQUES DE SEGMENTATION

La segmentation représente également un enjeu important dans le domaine du traitement d'image et à ce titre a fait l'objet d'abondants travaux et publications touchant les nombreux cas d'analyse dans lesquels une segmentation est utilisée. On peut citer la reconnaissance de formes, la détection et/ou la poursuite de cibles, la cartographie, le diagnostic médical, l'interaction Homme-machine, la discrimination d'arrière plan, etc.

On pourrait donner de la segmentation une définition spécifique par type d'usage, mais dans un souci d'unification, on propose la formulation générique suivante : "La segmentation consiste à distinguer les zones homogènes au sein d'une image". Dans cette définition, le caractère *homogène* s'entend au sens d'un critère pré établi, adapté aux contraintes particulières de traitement comme le type de bruit corrompant les images, le modèle d'image ou bien la dimension du signal observé \bar{v} selon que l'image est en couleur ou non. Un tel critère peut ainsi être un simple seuil de niveau de gris ou bien nécessiter de coûteux calculs statistiques dont certains seront détaillés dans les chapitres suivants.

Devant la diversité des cas à traiter et des objectifs à atteindre, on sait aujourd'hui qu'à

l'instar du filtre unique, la méthode universelle de segmentation n'existe pas et qu'une bonne segmentation est celle qui conduit effectivement à l'extraction des structures pertinentes d'une image selon l'interprétation qui doit en être faite.

Les éléments constitutifs de la segmentation sont soit des régions, soit des contours. Les deux notions sont complémentaires étant donné que les contours délimitent des régions, mais les techniques de calcul basés sur l'un ou l'autre de ces éléments relèvent d'abord différents.

Les algorithmes de segmentation orientés régions s'appuient pour beaucoup sur des techniques de regroupement, ou *clustering*, pour l'identification et le peuplement des régions. Ce lien trouve son origine dans la psychologie du *gestalt* [47] où l'on considère que la perception conceptuelle s'élabore au travers de regroupements visuel d'éléments.

Généralement, la plupart des approches proposées jusqu'à très récemment consistent à minimiser une fonction d'énergie qui n'a pas de solution formelle et que l'on résout donc à l'aide de techniques numériques, souvent itératives.

3.5.1/ ANALYSE D'HISTOGRAMME

Les techniques les plus simples à mettre en œuvre en segmentation sont les techniques de seuillage, basées sur une analyse de l'histogramme des niveaux de gris (ou de couleurs) et cherchant à en distinguer les différentes classes comme autant d'occurrences représentant des *régions* homogènes. Différents critères peuvent être appliqués pour cette analyse, visant par exemple à maximiser la variance [66] ou encore à maximiser le contraste pour déterminer les valeurs pertinentes des seuils.

Malgré la multitude de variantes proposées, ces méthodes demeurent toutefois peu robustes et présentent l'inconvénient majeur de ne pas garantir la connexité des régions déterminées. On les réserve à des applications très spécifiques où, par exemple, on dispose d'une image de référence dont l'histogramme peut être comparé à celui des images à traiter. C'est le cas de certaines application de contrôle industriel où la simplicité algorithmique permet de surcroît des implémentations très rapides, voire câblées.

Ces techniques peuvent aujourd'hui être considérées comme rudimentaires mais les calculs d'histogrammes et les analyses associées interviennent dans beaucoup d'algorithmes récents parmi les plus évolués et performants. La figure 3.10 illustre le traitement typique de l'histogramme de l'image d'entrée 3.10(a) dans le but de distinguer les deux régions du fond et du cochon (la cible). La première étape consiste à dresser l'histogramme des niveaux de gris sur tout le domaine de l'image 3.10(b). Il faut ensuite identifier le seuil de séparation des deux régions supposées, ici, homogènes au sens des valeurs de niveau de gris. Une estimation visuelle peut-être faite, mais on voit immédiatement que même dans une situation aussi claire, le choix du seuil n'est pas évident. Pour un traitement automatique, on peut par exemple proposer la technique itérative présentée par l'Algorithme 1 qui conduit à la segmentation de la figure 3.10(c). L'image 3.10(d) est l'image initiale, corrompue par un bruit gaussien de moyenne nulle et d'écart type 25. Les résultats de la segmentation (3.10(c) et 3.10(f)) de cette image sont clairement insuffisants le segment de la cible comporte des discontinuités et dans le cas de l'image bruitée, des pixels orphelins épars demeurent en quantité. Cette technique nécessiterait une étape supplémentaire pour disposer d'une segmentation pertinente.

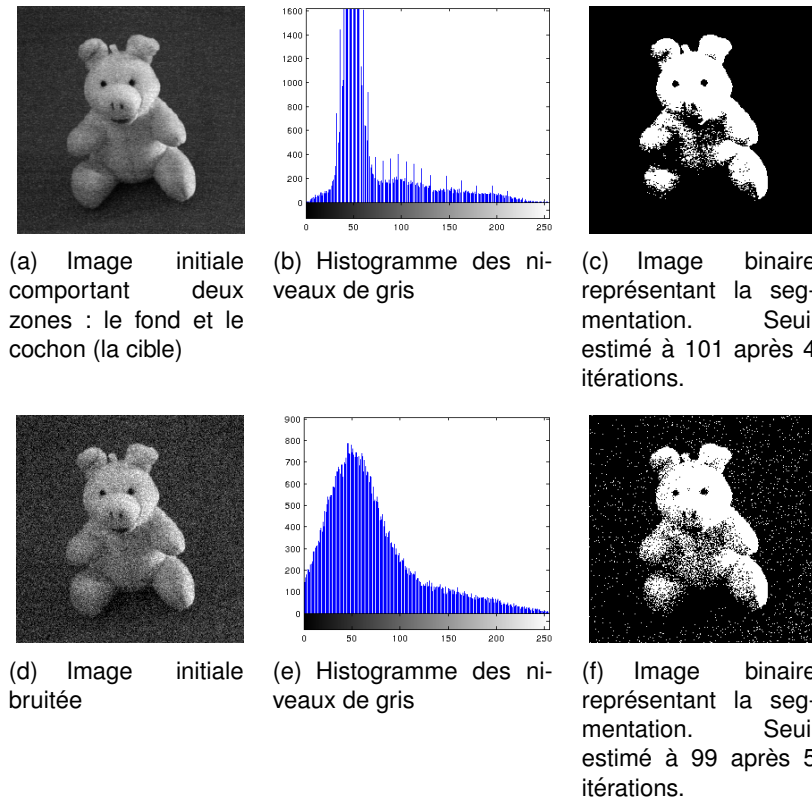


FIGURE 3.10 – Segmentation d’une image en niveaux de gris de 128×128 pixels par analyse simple d’histogramme. Colonne de gauche : image d’entrée. Colonne centrale : histogramme des niveaux de gris. Colonne de droite : résultat de la segmentation.

Algorithme 1 : Calcul du seuil de séparation des segments de l’histogramme.

- 1 $\bar{h} \leftarrow$ histogramme sur l’image ;
 - 2 $S_{init} \leftarrow 128$;
 - 3 $S_k \leftarrow S_{init}$;
 - 4 $\epsilon \leftarrow 1$;
 - 5 **repeat**
 - 6
$$\mu_{inf} = \frac{\sum_{i < S_k} h_i i}{\sum_{i < S_k} h_i} ;$$
 - 7
$$\mu_{sup} = \frac{\sum_{i \geq S_k} h_i i}{\sum_{i \geq S_k} h_i} ;$$
 - 8 $S_k = \frac{1}{2}(\mu_{inf} + \mu_{sup})$;
 - 9 **until** $\|S_k - \frac{1}{2}(\mu_{inf} + \mu_{sup})\| < \epsilon$;
-

3.5.2/ PARTITIONNEMENT DE GRAPHE

Un autre formalisme qui a généré une vaste classe d'algorithmes de segmentation est celui des graphes et repose sur l'idée que les régions de l'image sont représentées par les nœuds du graphe, alors que les liens traduisent les relations de voisinage existant entre les régions. L'idée de base est d'initialiser le graphe avec un nœud pour chaque pixel. La segmentation est obtenue par partitionnement itératif du graphe, en évaluant les liens et en déterminant ceux à supprimer et ce, jusqu'à convergence.

L'essentiel de la problématique réside donc dans la métrique retenue pour évaluer les liens ainsi que dans le critère de sélection et là encore, la littérature regorge d'une grande variété de propositions. Nous pouvons retenir que les premières d'entre elles, qui n'étaient pas spécifiquement dédiées à la segmentation d'images numériques mais au regroupement d'éléments répartis sur un domaine (1D ou 2D), ont été élaborées autour d'une mesure locale des liens basée sur la distance entre les éléments. La réduction du graphe est ensuite effectuée en utilisant un algorithme spécifique, comme le *minimum spanning tree*, dont l'application a été décrite dès 1970 dans [98] et où il s'agit simplement de supprimer les liens *inconsistants*, c'est à dire ceux dont le poids est significativement plus élevé que la moyenne des voisins se trouvant de chaque côté du lien en question.

L'extension a rapidement été faite aux images numériques en ajoutant l'intensité des pixels au vecteur des paramètres pris en compte dans l'évaluation du poids des liens. D'autres critères de partitionnement ont été élaborés, avec pour ambition de toujours mieux prendre en compte les caractéristiques structurelles globales des images pour prétendre à une segmentation qui conduise à une meilleure perception conceptuelle. Le principe général des solutions actuelles repose sur la construction d'une matrice de similarité qui traduit les liens entre les segments et représente le graphe à partitionner. Pour des images en niveaux de gris, l'expression générale des éléments w_{ij} de la matrice de similarité W est :

$$w_{ij} = \begin{cases} e^{\|v_i - v_j\|^2 / \sigma_v^2} e^{\|x_i - x_j\|^2 / \sigma_x^2} & \text{si } \|x_i - x_j\| < r \\ 0 & \text{sinon} \end{cases}$$

On construit également la matrice de connectivité D , diagonale et dont les éléments sont :

$$d_i = \sum_j w_{ij}$$

Une famille de méthodes, inspirée par le *graphe optimal* de Wu et Leahy [95], réalise le partitionnement sur la base des valeurs propres λ_k et vecteurs propres Y_k du système

$$(D - W)Y = \lambda DY$$

Certains algorithmes proposés plus récemment s'inscrivent dans cette veine [91, 92, 34, 78]. Le principal point faible de ces techniques réside essentiellement dans la difficulté à trouver un compromis acceptable entre identification de structures globales et préservation des éléments de détails. Cela se traduit dans la pratique par un ensemble de paramètres à régler pour chaque type de segmentation à effectuer.

La figure 3.11 montre un exemple de l'application de l'algorithme *normalized cuts* décrit dans [78] et implémenté par Cour, Yu et Shi en 2004. Cette implémentation utilise des valeurs pré-établies des paramètres de calcul de la matrice de similarité produisant de




FIGURE 3.11 – Segmentation d’une image en niveaux de gris de 128×128 pixels par simplification de graphe de type *Normalized cut* pour un nombre s de segments variant de 2 à 5.

bonnes segmentations d’objets et/ou personnes dans les images naturelles, mais requiert de prédéterminer le nombre de segments à obtenir. Les images de la figure représentent les résultats obtenus avec un nombre de segments variant de 2 à 5 et montrent qu’il est difficile de trouver un compromis acceptable. Enfin, les temps d’exécutions peuvent devenir très rapidement prohibitifs, même avec des implémentations plus optimisées. Pour information, les résultats de la figure 3.11 ont été obtenus en 1.5 s environ (Matlab R2010 sur CPU intel core i5-2520M @ 2.50GHz - linux 3.2.0)

Un autre procédé de partitionnement de graphe, reposant sur le théorème dit du *maximum flow-minimum cut* énoncé par Ford et Fulkerson [37] a fait l’objet de beaucoup de travaux. Des comparaisons en sont rapportées dans [11, 18]. Plusieurs algorithmes mettent en œuvre ce procédé avec de bons résultats, comme la méthode du *push-relabel* [23] ou le *pseudoflow* [45] qui semble aujourd’hui le plus performant.

3.5.3/ KERNEL-MEANS, MEAN-SHIFT ET APPARENTÉS

Parallèlement à la réduction de graphes, d’autres approches ont donné naissance à une multitude de variantes tournées vers la recherche des moindres carrés. Il s’agit simplement de minimiser l’erreur quadratique totale, ce qui peut se résumer, pour une image de N pixels, en la détermination du nombre C de segments Ω_i et leur contenu, de sorte à minimiser l’expression

$$\sum_{i \in [1..C]} \sum_{x_k \in \Omega_i} (v_k - \mu_i)^2$$

où μ_i représente la valeur affectée au segment Ω_i , i.e la valeur moyenne des observations v_k sur Ω_i , et $\bigcup_{i \in [1..C]} \Omega_i = \Omega$

Cette idée est très intuitive et simple, mais n’a pas souvent de solution explicite, d’autant que le nombre des segments est *a priori* inconnu. Dès 1965, MacQueen a proposé l’appellation k-means pour cette procédure itérative de regroupement [59] qui débute avec k groupes d’un seul pixel¹ pris au hasard, puis d’ajouter chaque point au groupe dont la moyenne est la plus proche de la valeur du point à ajouter. La moyenne du groupe nouvellement agrandi doit alors être recalculée avant le prochain ajout. Cette implémentation est extrêmement simple à mettre en œuvre² mais elle possède de nombreux défauts dont le principal est qu’elle ne converge pas nécessairement vers le regroupement optimal,

1. Dans son article, MacQueen ne parle pas de pixel mais de point. En effet, la méthode décrite ne visait pas à segmenter des images, mais des données de natures diverses.

2. Même si en 1965, rien n’était simple à programmer




FIGURE 3.12 – Segmentation d’une image en niveaux de gris de 128×128 pixels par algorithme k -means pour un nombre s de segments variant de 2 à 5. Chaque couleur est associée à un segment. Les couleurs sont choisies pour une meilleure visualisation des différents segments.

même si on connaît la “bonne” valeur de k . Un autre est d’être très dépendant du choix des k éléments initiaux, en nombre et en position.

Toutefois, vraisemblablement du fait de sa simplicité d’implémentation et de temps d’exécution rapides, la communauté scientifique s’est beaucoup penchée sur cette méthode pour en compenser les défauts, jusqu’à en faire une des plus employées, en particulier par les statisticiens. On compte aussi beaucoup de variantes telles les k -centers [4] et les k -médiants [7] qui n’emploient pas la moyenne arithmétique comme expression du “centre” d’un segment. Des solutions ont aussi été apportées pour l’estimation de k en employant, par exemple, un critère de vraisemblance pour choisir la meilleure valeur de k dans un intervalle donné [68]. À titre d’illustration et de comparaison, l’image du cochon a été traitée par une implémentation naïve de l’algorithme original des k -means en donnant successivement au nombre de segments les valeurs $s = 2$ à $s = 5$. Les résultats sont reproduits à la figure 3.12 et montrent encore une fois l’influence de s sur la segmentation.

Un algorithme initialement proposé en 1975 par Fukunaga et Hostetler [38] permet de manière plus générique de déterminer le nombre de segments, ou modes, ainsi que les points, ou pixels, qui les composent. Il cherche pour ce faire à localiser les k positions où le gradient de densité s’annule. Il utilise un voisinage pondéré (ou *kernel*) et détermine le centre de masse des segments en suivant itérativement le gradient de densité dans le voisinage autour de chaque élément du domaine. Lorsque l’algorithme a convergé, les k segments sont identifiés et contiennent chacun l’ensemble des points qui ont conduit à leur centre de masse respectif. Étonnement, malgré ses qualités intrinsèques, cet algorithme du *mean-shift* est resté longtemps sans susciter de grand intérêt, jusqu’à l’étude de Cheng [22] qui en a démontré les propriétés et établi les liens avec d’autres techniques d’optimisation comme la descente/montée de gradient ou de filtrage comme le floutage. Comaniciu et Peer ont alors étendu l’étude et proposé une application à la segmentation en utilisant l’espace colorimétrique CIELUV [36] et montré qu’elle permettait une meilleure identification des modes de l’image [26, 27]. Une implémentation de la variante proposée par Keselman et Micheli-Tzanakou dans [51] appliquée à notre image de test fournit les résultats reproduits à la figure 3.13. Pour se rapprocher des traitements précédents, nous avons identifié, par essais successifs, les tailles de voisinage conduisant à des nombres de segments identiques à ceux des figures précédentes (de 2 à 5). Le volume minimal admis pour un segment a été arbitrairement fixé à 100 pixels.

Il est à noter que les segmentations basées sur des algorithmes de *clustering* comme ceux que l’on vient de présenter nécessitent le plus souvent une phase supplémentaire de




FIGURE 3.13 – Segmentation d’une image en niveaux de gris de 128×128 pixels par algorithme *mean-shift* pour un rayon de voisinage r de 100, 50, 35 et 25 pixels permettant d’obtenir un nombre s de segments variant respectivement de 2 à 5. Le volume minimal admis pour un segment est fixé à 100 pixels. Chaque couleur est associée à un segment. Les couleurs sont choisies pour une meilleure visualisation des différents segments.

génération des frontières inter-segments et d’affectation de la valeur de chaque segment aux éléments qui le composent. Par ailleurs, dans les deux cas du *k-means* et du *mean-shift*, chaque itération génère une réduction de la variance (due au moyennage) et on peut donc rapprocher ces techniques de celles de réduction de bruit par minimisation de variance.

3.5.4/ LES CONTOURS ACTIFS, OU *snakes*

Contrairement aux précédentes techniques et comme leur nom le laisse deviner, les éléments constitutifs de ces méthodes sont cette fois des *contours* et non plus des *régions*. De fait, ils définissent nativement une segmentation de l’image. Le principe général est de superposer une courbe paramétrique S à l’image, le *snake*, puis de lui appliquer des déformations successives destinées à rapprocher le *snake* des contours de l’objet. Les déformations à appliquer sont guidées par l’évaluation d’une fonction d’énergie E_{snake} prenant en compte :

- l’énergie interne E_{int} de la courbe, fonction de son allongement de sa courbure.
- l’énergie externe E_{ext} liée à l’image, fonction de la proximité de la courbe avec les zones de fort gradient et éventuellement une contrainte fixée par l’utilisateur comme des points imposés par exemple.

L’expression générique peut alors s’écrire

$$E_{snake} = E_{int} + E_{ext}$$

où

$$E_{int} = \sum_{s \in S} \frac{1}{2} \left(\alpha \left| \frac{\partial x_s}{\partial s} \right|^2 + \beta \left| \frac{\partial^2 x_s}{\partial s^2} \right|^2 \right) ds$$

et

$$E_{ext} = \sum_{s \in S} -|\nabla [G_\sigma(x_s) * v_s]|^2 ds$$

L’idée générale de l’algorithme du *snake* est de trouver une courbe S qui minimise l’énergie totale E_{snake} . Ici encore, la résolution du problème revient donc à minimiser une fonction sous contrainte et les diverses techniques de résolution numérique peuvent s’appliquer comme pour les autres classes d’algorithmes itératifs présentés précédemment, avec ici encore, un nombre de paramètres à régler assez important. Notons également




FIGURE 3.14 – Segmentation d'une image en niveaux de gris de 128×128 pixels par l'algorithme dit du *snake*, dans sa version originale. Les paramètres d'élasticité, de raideur et d'attraction ont été fixés respectivement aux valeurs 5, 0.1 et 5.

que dans le cas général, les paramètres notés α et β , que l'on qualifie aussi d'élasticité et de raideur, sont aussi des fonctions de l'abscisse curviligne s . La fonction G_σ est la fonction d'attraction aux forts gradients de l'image.

Dans sa version originale proposée par Kass *et al.* en 1988 [50], l'algorithme dit du *snake* présente l'intérêt de converger en un nombre d'itérations assez réduit et permet de suivre naturellement un *cible* en mouvement après une convergence initiale à une position donnée, chaque position de convergence fournissant une position initiale pertinente pour la position suivante. Toutefois, il se montre particulièrement sensible à l'état initial de la courbe et requiert souvent de celle-ci qu'elle soit assez proche de l'objet à "entourer", sous peine de se verrouiller dans un minimum local. La sensibilité au bruit n'est pas non plus très bonne du fait de la formulation locale de l'énergie. Les "concavités" étroites ou présentant un goulot d'étranglement marqué sont par ailleurs mal délimitées. Enfin, la fonction d'énergie étant calculée sur la longueur totale de la courbe, cela pénalise la bonne identification des structures de petite taille vis à vis de la longueur totale de la courbe. La figure 3.14 illustre ces défauts en montrant quelques états intermédiaires ainsi que le résultat final d'une segmentation réalisée à partir d'un contour initial circulaire et des paramètres à valeurs constantes et réglés empiriquement, en employant la méthode du *snake* original. On voit que la convergence est assez rapide mais que le contour ainsi déterminé ne "colle" pas bien à l'objet que l'on s'attend à isoler.

Il est cependant possible de contrôler la finesse de la segmentation mais au prix de temps de calculs qui peuvent devenir très longs. Parmi les variantes élaborées qui tentent de pallier ces défauts, les plus intéressantes sont :

- le *balloon snake*, conçu pour remédier au mauvais suivi des concavités en introduisant une force supplémentaire de pression tendant à *gonfler* le *snake* jusqu'à ce qu'il rencontre un contour suffisamment marqué. Cela suppose toutefois que l'état initial de la courbe la situe entièrement à l'intérieur de la zone à segmenter et est surtout employé dans des applications semi-automatiques où l'utilisateur définit au moins une position et une taille initiales pour la courbe.
- le *snake GVF* (pour Gradient Vector Flow), dont le but est de permettre qu'une initialisation lointaine de la courbe ne pénalise pas la segmentation. Une carte des lignes de gradient est établie sur tout le domaine de l'image et sert à intégrer une force supplémentaire dans l'énergie totale, qui attire la courbe vers la zone de fort gradient.
- les *level-sets*, dont la particularité est de ne pas employer directement une courbe pa-

ramétrique plane mais de définir l'évolution des frontières comme l'évolution temporelle de l'ensemble des points d'une surface 3D soumise à un champ de force, tels que leur élévation soit constamment nulle. Les propriétés des contours actifs par *level-sets* se sont révélées intéressantes, en particulier la faculté de se disjoindre ou de fusionner, mais les temps de calcul très pénalisants. Après la formulation initiale de Osher et Sethian en 1988 [65], plusieurs façon de réduire le coût du calcul ont été formulées, dont les plus importantes restent les techniques dites *narrow band* [3] (bande étroite) qui ne calcule à chaque itération que les points dans une bande étroite autour du plan $z = 0$ de l'itération courante et *fast marching* [76] qui s'applique dans le cas particulier d'une évolution monotone des fronts.

- les *snake* orientés régions, qui visent essentiellement à mieux caractériser les zones à segmenter et améliorer la robustesse vis à vis du bruit en employant une formulation de l'énergie calculée sur le domaine complet de l'image [25, 73]. Les premiers résultats confirment la qualité de cette méthode, mais la nécessité d'effectuer les calculs sur l'image entière générerait des temps de traitement prohibitifs jusqu'à ce que Bertaux *et al.* proposent une amélioration algorithmique exacte permettant à nouveau un calcul en 1D, le long de la courbe, moyennant une simple étape initiale générant un certain nombre d'images intégrales [24, 40, 41]. La section ?? qui introduit notre contribution à cette technique en donnera une description détaillée.

3.5.5/ MÉTHODES HYBRIDES

Aujourd'hui, les algorithmes de segmentation les plus performants en terme de qualité emploient des techniques qui tentent de tirer le meilleur parti de plusieurs des méthodes "historiques" décrites précédemment. Le meilleur exemple, et le seul que nous citerons, est le détecteur de contour et l'algorithme de segmentation associé proposé par Arbelaez *et al.* en 2010 [6]. Il compose avec la constructions d'histogrammes locaux pour générer une matrice de similitude (affinity matrix) et appliquer les techniques liées à la théorie des graphes pour réduire la dimension de l'espace de représentation (calcul des valeurs et vecteurs propres). Il utilise ensuite une technique adaptée de *ligne de partage des eaux* (que l'on aurait rangée avec les mean-shift) pour regrouper les segments. Les résultats sont très bons et des implémentations efficaces ont d'ores et déjà été écrites (voir section ??).

3.6/ LES IMPLÉMENTATIONS GPU DES TECHNIQUES DE SEGMENTATION

La problématique tant étudiée de la segmentation n'a pas échappé à l'engouement des chercheurs pour les processeurs graphiques modernes. Un certain nombre de travaux proposent ainsi des implémentations GPU plus ou moins directes de méthodes de segmentation tirant parti de l'architecture massivement parallèle de ces matériels. La majorité d'entre elles cherche à répondre à des besoins liés à l'imagerie médicale allant de la simple extraction des contours d'un organe, d'une tumeur, etc., à la mesure de leur volume ; le traitement en 3D n'étant dans ce cas pas un choix mais une obligation, justifiant d'autant plus l'emploi des GPU. La natures des tissus et les formes à identifier sont extrêmement variées. Les images sont souvent très bruitées et les modèles de bruit di-

vers selon l'instrumentation employée. Enfin, le diagnostique médical requérant la plus grande précision possible, aucune solution générique satisfaisante de segmentation n'a encore pu émerger dans ce cadre, laissant place à autant d'implémentations adaptées que de besoin médical spécifique.

Beaucoup d'algorithmes récents destinés à la segmentation comportent plusieurs phases de calcul et mettent en œuvre différents algorithmes réalisant des fonctions élémentaires comme de la réduction de bruit ou du calcul d'histogramme. Selon le type de traitement à effectuer sur le GPU, on peut-être amené à en concevoir des implémentations parallèles adaptées ou bien simplement exécuter indépendamment, pour chaque pixel par exemple, de multiples instances d'une version séquentielle classique du traitement. Dans les deux cas, on lira "implémentation GPU", mais cela recouvrira des réalités et parfois aussi des niveaux de performance très différents.

3.6.1/ CALCUL D'HISTOGRAMME

Comme il a été dit au paragraphe 3.5.1, les segmentations par analyse d'histogramme sont aujourd'hui cantonnées à des applications très particulières et leurs implémentations GPU ne font pas l'objet de recherches, d'autant que dans la pratique, ces traitements sont souvent réalisés par des circuits spécialisés ou programmables de type FPGA et qu'il serait illusoire d'espérer les concurrencer par une solution de type gpu, plus coûteuse, plus volumineuse et vraisemblablement moins robuste.

Le calcul d'histogramme est cependant utilisé de manière intensive dans certains algorithmes de haut-niveau, en particulier le *level-set* et le *gPb*. À ce titre, il faut citer les travaux de Fluck *et al.* [35] qui apportent une réponse efficace au calcul d'histogramme sur le GPU leur permettant de conserver les données dans la mémoire du processeur graphique tout au long de l'exécution de la segmentation par level-set qui leur a servi de motivation [55].

Les résultats annoncés ont été obtenus sur un GPU GeForce 7900 et font état du calcul des deux histogrammes nécessaires (64 classes chacun) sur une image de 256×256 pixels en niveau de gris en 1.6 ms.

3.6.2/ PARTITIONNEMENT DE GRAPHE

Le domaine du traitement des graphes est très actif et peut fournir des éléments pour la segmentation comme l'implémentation du *minimum spanning tree* décrite dans [89] qui annonce la construction du minimum spanning tree d'un graphe de 5 millions de nœuds et 30 millions de liens en moins d'une seconde. La parallélisation GPU des opérations sur les graphes n'est pas simple en raison de l'indépendance des blocs de threads. Peu de travaux font encore état d'implémentations efficaces mettant en œuvre ces techniques. On ne recense que quelques propositions GPU de l'algorithme *push-relabel* pour le partitionnement selon l'approche *min cut/max flow* dont on ne retient que les trois remarquables détaillée ci-dessous.

Dans [32] une approche assez directe est mise en œuvre et parvient à *binariser* une image de 1 MP en 29 ms (GeForce 6800GT).

Les auteurs de [88] remarquent qu'après un nombre réduit d'itérations, très peu de nœud




FIGURE 3.15 – Évolution du nombre de pixels actifs pour les itérations successives de l'implémentation de l'algorithme push-relabel de [81]. Les petites images montrent la localisation des pixels actifs après chaque itération, en blanc.

se voient changer de segment. En conséquence, certains blocs de traitement sont activés alors qu'ils n'ont effectivement pas de traitement à effectuer et retardent ainsi les traitements éventuels des blocs en attente. Pour réduire les effets de ce comportement, un indicateur d'activité est calculé à chaque itération et pour chaque bloc, en se basant sur le nombre de changements de segment qui viennent d'y être effectués. À l'itération suivante, seuls les blocs considérés comme *probablement* actifs seront activés, réduisant ainsi la latence globale. Un reparamétrage dynamique du graphe après chaque itération est également effectué selon la méthode décrite par Kohli et Torr [53]. Ces optimisations permettent d'atteindre un débit d'environ 30 images de 0.3 MP par seconde sur GTX280, ce qui représente un bond en terme de performance.

Enfin, Stitch a proposé dans [81] des optimisations plus étroitement liées à l'architecture des GPU Nvidia en faisant qu'un même thread mette à jour plusieurs liens du graphe et aussi en compactant la représentation des indicateurs de changement de segment par 32 par l'emploi d'un seul bit par lien. Cela a permis d'accélérer la convergence de l'algorithme, comme la montre la courbe de la figure 3.15 (tirée de [81]), et d'atteindre les 70 images par seconde dans les mêmes conditions que précédemment (sur C1060). Il faut noter aussi que sur C1060, l'implémentation décrite dans [88] est moins performante, avec 17 fps, que sur la carte GTX280.

3.6.3/ K-MEANS, MEAN-SHIFT ET APPARENTÉS

La popularité de l'algorithme des *k-means* a induit des tentatives de portage sur GPU dont [19] qui a implémenté de manière directe l'étiquetage des éléments ainsi qu'une réduction partielle, par bloc, pour la mise à jour des centres ; la réduction finale étant réalisée par le CPU. Cette solution conduit à un transfert des données à chaque itération et ne permet pas d'atteindre des performances élevées. La mesure de performance a été faite avec la base de test KDD-Cup-99 [1], comportant 23 segments. Le temps annoncé pour l'exécution d'une seule itération sur un ensemble de 819200 éléments est de 200 ms. Toutefois, cette durée n'inclut pas la réduction ni les transferts et l'accélération revendiquée semble alors très discutable.

Dans [46], l'ensemble des tâches d'étiquetage et de mise à jour des centres est réalisé sur le GPU. Une étape de réorganisation des données est encore exécutée sur le CPU,

mais elle s'avère moins pénalisante que la solution présentée précédemment, puisqu'elle permet de présenter au GPU des données permettant d'optimiser l'exécution parallèle de l'étape de réduction suivante (mise à jour des centres). Les temps d'exécution par itération sont sensiblement les mêmes que pour [19] mais ils incluent cette fois l'ensemble des calculs (hors transferts). Les auteurs fournissent cette fois des mesures des temps d'exécution à convergence, qui atteignent la vingtaine de secondes pour le même ensemble de test.

La plus convaincante des implémentations de *k-means* reste à notre connaissance celle décrite dans [77] et où la totalité du traitement est effectuée sur le GPU, moyennant l'emploi d'une texture par segment de données. Les mesures ont montré que cette multiplication du nombre des textures ne constituait pas un facteur de perte de performance, tout du moins jusqu'aux limites des tests, conduits avec un maximum de 32 segments dans des ensembles de 1 million d'éléments. Sur GPU GeForce 8500GT, les temps d'exécution obtenus dans ces conditions sont de 13.8 ms par itération, avec une dépendance très réduite vis à vis du nombre de segments.

Des travaux à orientation non médicale mettent en œuvre sur GPU un algorithme de *mean-shift* pour la poursuite de cibles dans des séquences vidéo [57]. L'accélération obtenue par rapport aux implémentations séquentielles existantes n'est que d'un facteur 2. La solution présentée effectue préalablement une réduction de l'espace colorimétrique via un regroupement par la méthode *k-means*, utilisée dans une version séquentielle. Un gain potentiel de performance pourrait être apporté en employant une implémentation GPU du *k-means*, mais serait toutefois limité en raison des itérations nécessaires plus nombreuses pour le traitement *mean-shift*. Par ailleurs, l'implémentation proposée fait un usage intensif de la mémoire partagée et se heurte à sa limite de 16 Ko par bloc, obligeant à réduire la taille des blocs à l'exécution et avec eux, le parallélisme et vraisemblablement aussi la performance de l'application. On peut malgré tout raisonnablement espérer qu'une telle solution présenterait des performances meilleures sur une carte de type Fermi possédant jusqu'à 48 Ko de mémoire partagée par bloc.

Quick shift, une approximation de l'algorithme *mean-shift* gaussien, c'est à dire utilisant des masques de pondération gaussiens, permettant d'obtenir un résultat en une seule passe (sans itérer) et proposée initialement dans [87] a été parallélisée sur GPU par ses auteurs et décrite dans [39]. La recherche de performance se traduit par des approximations, en particulier on restreint les calculs de pondération à des voisinages de rayon 3σ (écart type de la gaussienne définissant les coefficients du masque), considérant qu'au delà, les valeurs en sont négligeable. Ensuite on construit un arbre des liens entre les pixels, mais on limite la recherche à une distance maximale de σ . Par ailleurs, on diminue arbitrairement la dynamique de l'espace colorimétrique par 2. Enfin, la segmentation est obtenue par simple partitionnement de l'arbre selon un seuil τ . Pour s'affranchir de la relative petite taille de la mémoire partagée sans devoir pâtir de la grande latence des accès à la mémoire globale de GPU, les auteurs ont ici choisi d'associer l'image et l'estimation de densité à des textures et ainsi bénéficier du mécanisme de cache. Les expérimentations ont été menées avec différentes valeurs de σ et τ choisies pour les résultats visuels qu'elles induisent et permettent de segmenter une image couleur de 1 MP en environ 1 s avec $\tau = 10$ et $\sigma = 6$. Toutefois, des valeurs plus petites, requérant moins de calculs, permettent des temps d'exécution beaucoup plus courts. Les courbes présentées permettent d'envisager, pour $\tau = 4$ et $\sigma = 2$, une réduction par 30, soit environ 33 ms. Une version améliorée récemment, dans laquelle les positions des centres sont stockées en registres, permet selon les auteurs, de diviser encore par 2 les temps




FIGURE 3.16 – Segmentation d'une image couleur de 512×512 pixels par l'implémentation GPU quick-shift de [39].




FIGURE 3.17 – Segmentation d'une image couleur de 2256×3008 pixels.

d'exécution pour atteindre une segmentation en environ 16.5 ms. La figure 3.16, tirée de [39], présente quelques segmentations effectuées avec des valeurs différentes, permettant ainsi de juger des effets des variations des paramètres τ et σ .

Récemment, Xiao et Liu ont décrit dans [96] une implémentation de l'algorithme *mean-shift* qui utilise cette fois une construction de *KD-tree* (arbre binaire à K dimensions) pour réduire l'espace colorimétrique et effectuer rapidement les recherches des plus proches voisins. L'ensemble s'exécute sur le GPU et permet ainsi d'obtenir des résultats beaucoup plus probants puisque les auteurs revendiquent une segmentation d'image couleur de 6.6 millions de pixels en 0.2 secondes. Malheureusement, il n'est pas dit combien de segments comprend l'image et il n'est fait référence qu'à une seule image, dont on déduit qu'il s'agit de l'image reproduite à la figure 3.17 afin de montrer les différences avec une implémentation standard du *mean-shift*.

3.6.4/ SNAKES ET LEVEL SET

Dès 2003, on recense d'importants travaux liés à l'imagerie médicale mettant en œuvre des algorithmes *level set* sur GPU. C'est le cas de [54, 55] où les auteurs décrivent une solution de visualisation des coupes d'une mesure volumique réalisés par résonance magnétique (IRM) en exploitant pour la première fois le caractère creux du système

d'équations à résoudre, *i.e.* variante *narrow-band*, contrairement à la première solution 2D présentée dans [74] qui implémente la version standard. En ne transférant au GPU, pour chaque itération, que les petits pavés de données actifs et en les rangeant alors de manière contigue en texture pour optimiser les accès en lecture, les auteurs sont ainsi parvenu à effectuer, pour des données volumiques de $256 \times 256 \times 175$, entre 3.5 et 70 itérations par seconde, à comparer aux 50 itérations par seconde en 2D sur image de 128^2 pixels obtenues dans [74]. La limitation principale de cette solution est celle des dimensions maximales admises pour une texture qui était de 2048^2 pour le GPU ATI Radeon 9800 pro employé (et programmé en OpenGL, car ni openCL ni CUDA n'étaient encore disponible à l'époque). Les autres solutions GPU proposées depuis sont également basées sur la variante *narrow-band* (bande étroite) des *level-set* [56, 17, 48], mais seule [48] s'affranchit des transferts CPU/GPU à chaque itération pour déterminer et transférer les pavés actifs. La solution retenue est d'employer les opérations atomiques pour assurer l'accès exclusif à la liste des pavés en mémoire GPU. Cela permet de descendre à 3 ms par itération pour une image de 512^2 pixels.

La plus performante des implémentations à ce jour est celle décrite dans [72] qui parvient à des itérations dont la durée varie, sur GTX280, de 1.8 à 6.5 ms pour des données volumiques de 256^3 pixels issues d'examen IRM, pour une moyenne de 3.2 ms sur les 2200 itérations de l'exemple fourni (cerveau en 7 s, Figure 3.18(a)). Une optimisation poussée y a été effectuée pour rendre l'algorithme efficace, en particulier au travers de la refonte du code responsable de la détermination des pavés actifs. Il parvient cette fois à déterminer l'ensemble minimal de pavés actifs et à rendre cette détermination efficace sur le GPU en gérant parallèlement plusieurs tampons, chacun associé à une direction particulière en 6-connexité. Une étape de résolution des doublons est ensuite effectuée avant de les compacter de manière contigue comme cela était déjà fait dans [54]. Tout cela est réalisé sans recourir à la mémoire partagée qui s'avère complexe voire impossible à utiliser efficacement lorsque les éléments à accéder sont très irrégulièrement répartis en mémoire.

Ce faisant, le nombre cumulé total de pavés ainsi traités lors des 2200 itérations de la segmentation de l'image d'exemple s'élève à 294 millions à comparer aux 4877 millions traités par l'algorithme *narrow-band* standard. Il est à noter que la durée d'exécution d'une itération dans cette variante dépend plus fortement de la proportion de pavés actifs que pour *narrow-band* standard. Les deux courbes sont globalement affines et se croisent pour une proportion de pavés actifs proche de 10%. Si l'on considère que malgré les stratégies adoptées, tenir à jour cette liste de pavés représente encore 77% du temps de calcul, cela peut représenter une piste pour une optimisation supplémentaire qui ne semble pas se justifier avec l'image et l'initialisation dont les performances sont détaillées, mais qui pourrait l'être dans d'autres conditions, comme peut le suggérer le temps de segmentation de 16 s nécessaire pour l'image des reins (Figure 3.18(b)) et de l'aorte, aux dimensions comparables.

Les algorithmes de type *snake*, très coûteux en temps de calcul, pouvaient prétendre à bénéficier largement de la technologie des GPU pour améliorer leurs performances, mais seule la variante paramétrique GVF a véritablement été implémentée de manière spécifique et efficace [43, 8, 58, 79]. Les variantes de type géométrique, principalement en raison de l'irrégularité des motifs d'accès à la mémoire, restent à ce jour sans implémentation GPU. Parmi les premières solutions décrites, [43] propose une implémentation réalisée en OpenGL, où les données de gradient sont compactées en texture RVBA de manière à s'affranchir du format 16 bits de la représentation : les deux




FIGURE 3.18 – Segmentation d’images issues d’examen IRM par la méthode des level set à bande étroite.




FIGURE 3.19 – Segmentation d’une image d’épaule en 1024^2 pixels issue d’un examen IRM par l’implémentation du snake GVF de [43]. Le contour est représenté en rouge et le contour final est obtenu en 11 s.

premiers canaux R et V contiennent les valeurs représentant respectivement le gradients selon dx et dy sous une forme codée par la valeurs des 2 autres canaux. Par ailleurs, une approximation du système linéaire à résoudre est proposée afin de donner une structure bande symétrique à la matrice à inverser, ce qui améliore considérablement l’efficacité des accès aux données au travers du cache.

Les performances annoncées montrent tout d’abord que l’approximation adoptée n’a qu’un impact extrêmement limité sur le résultat de la segmentation avec un écart radial maximal inférieur à 1.3 pixel par rapport au calcul exact effectué sur CPU. Enfin, la segmentation de l’image d’exemple en 1024^2 pixels s’effectue en un total de 11 s après l’initialisation manuelle reproduite à la figure 3.19. Cela est annoncé comme presque 30 fois plus rapide que l’implémentation CPU de référence, mais demeure beaucoup trop lent pour un usage interactif.

Une solution directe employant la transformée de fourier pour inverser le système à résoudre a été décrite récemment dans [100] et programmée en employant la bibliothèque OpenGL. Les exemples fournis montrent des objets segmentés dans des images d’environ 10000 pixels en une durée de l’ordre de la demi seconde.

En adaptant sur GPU une variante dite FD-snake [58] du snake GVF (pour Fourier Descriptors) permettant une convergence plus rapide et un calcul parallèle beaucoup




FIGURE 3.20 – Extraction de contour par la version GPU de l'algorithme gPb. Les images sont issues de la base BSDS [62]

plus adapté au GPU, Li *et al.* parviennent quant à eux à suivre les déformations d'un contour en temps réel dans des images issues d'examen échographique ; Un contour de 100 points pouvant converger convenablement en à peine 30 ms. Une contribution supplémentaire de cette implémentation est de permettre une initialisation simplifiée et semi-automatique du contour.

La plus aboutie des implémentations actuelles du snake GVF est enfin celle présentée par Smistad *et al.* dans [79] et où les auteurs ont concentré leur effort sur l'optimisation des accès mémoire lors du calcul du GVF. Ils ont comparé 8 combinaisons possibles impliquant l'emploi des mémoires partagées et de texture ainsi que la représentation des nombres selon le format classique 32 bits ou selon un format compressé sur 16 bits. Il en ressort que l'association la plus performante est celle des textures et du format de données sur 16 bits. Les performances sont alors nettement en hausse avec des segmentations d'images médicales d'IRM de 512^2 pixels effectuées en 41 ms sur Nvidia C2070 et 28 ms sur ATI 5870 (512 itérations). L'implémentation réalisée en OpenGL permet d'exécuter le code sur les GPU des deux principaux fabricants.

3.6.5/ ALGORITHMES HYBRIDES

Le détecteur de contour *gPb* décrit dans [6] et que l'on considère comme la référence actuelle pour la segmentation d'objets et personnages dans des images naturelles, a été implémenté en CUDA par Catanzaro *et al.* et est décrit dans [16]. La qualité des contours extraits y est préservée et le temps de traitement y est réduit d'un facteur supérieur à 100 : les contours des images de 0.15 MP de la base de test BSDS [62] sont ainsi traitées en 2 secondes environ sur GPU C1060. L'apport principal de ces travaux réside dans la solution conçue pour le calcul des histogrammes locaux, qui dans l'algorithme original s'étendaient sur des demi-disques centrés sur chaque pixel. La parallélisation réalisée fait l'approximation de chaque demi-disque en un rectangle de même surface dont un des grands cotés à le centre du disque pour milieu. Les rectangles sont ensuite pivotés par une rotation basée sur la discrétisation de Bresenham [12] pour en aligner les cotés avec les cotés de l'image et pouvoir employer la technique des images cumulées pour calculer rapidement l'histogramme. La figure 3.20 présente quelques résultats d'extraction de contours.

3.7/ CONCLUSION

La présentation que nous venons de faire des principales techniques de filtrage et de ségmentation ainsi que des implémentations sur GPU qui leur ont été consacrées nous ont permis de mettre une évidence en lumière : malgré leur orientation grand public et les langages de haut niveau permettant d'accéder rapidement à la programmation GPU, la parallélisation efficace d'un algorithme séquentiel destiné à s'exécuter sur ces processeurs n'est pas triviale. Le modèle et les contraintes de programmation leur sont spécifiques et obtenir un code rapide découle nécessairement d'un compromis qui peut parfois être complexe à affiner.

Ajoutons que les générations de GPU qui se succèdent conservent certes des caractéristiques communes mais diffèrent suffisamment quant-à la distribution des ressources, rendant toute généralité vaine et faisant qu'un code optimisé pour un modèle donné peut devenir moins rapide avec un modèle plus récent. Prenons l'exemple du nombre maximal de registres utilisables par thread ; il est de 128 sur GPU C1060 contre seulement de 63 pour un C2070. Un code faisant un usage optimisé des registres sur C1060 pourra s'exécuter plus lentement sur C2070. C'est un cas de figure sur lequel nous reviendrons plus en détail dans le chapitre consacré au filtre médian.

Cet état de fait rend les résultats publiés par les chercheurs souvent délicats à interpréter et plus encore à reproduire lorsque l'on souhaite comparer les performances de nos propres codes avec les références du moment, sauf à disposer d'un panel de cartes GPU représentant toutes les évolutions de l'architecture et ce pour au moins les deux grands fabricants de GPUs que sont ATI et Nvidia.

Pour aider les développeurs à allouer les ressources de manière optimale, ou tout du moins estimer le degré d'optimisation de leur code à l'aune de la vitesse d'exécution, Nvidia fournit une feuille de calcul appelée *occupancy calculator* dans laquelle on peut entrer les paramètres d'exécution d'un *kernel* parallèle : nombre de registres utilisés par chaque thread, quantité de mémoire partagée, modèle de GPU, dimensions de la grille. Le tableur retourne alors l'indice de charge (l'occupancy) qui traduit le rapport, à chaque instant, entre le nombre de warps actifs et le nombre maximal de warps par processeur (SM = Streaming Multiprocessor). L'occupancy se traduit donc par un indice compris entre 0 et 100% et la recherche de performance semble devoir être la recherche de l'occupancy maximale.

Toutefois, comme l'a clairement démontré Volkov dans [90], ce paradigme peut aisément être remis en cause et Volkov parvient effectivement à améliorer les performances d'un certain nombre d'exemples génériques dans des conditions de faible valeur d'occupancy. Enfin, nous avons pu constater deux grands modèles d'accès aux données : les algorithmes de filtrage usent quasiment tous de la mémoire partagée comme tampon d'accès aux données de l'image en mémoire globale (ou texture) alors que les algorithmes de ségmentation performants s'en affranchissent. La raison en est clairement des motifs d'accès très irréguliers et non contigus pour ces derniers, rendant la gestion efficace de la mémoire partagée délicate et potentiellement si coûteuse qu'elle en devienne sans intérêt. Les chapitres suivants présentant nos contributions reviendront sur ces aspects en proposant des solutions pour accroître la performance des algorithmes parallélisés.

LA SEGMENTATION PAR SNAKE POLYGONAL ORIENTÉ RÉGIONS

4.1/ PRÉSENTATION DE L'ALGORITHME

La principale difficulté soulevée par l'emploi d'algorithmes de type *snake* orientés contour est le choix de la fonction d'énergie externe et la détermination de la nature des images auxquelles elle convient. Dans l'approche orientée régions, les deux régions que sont l'extérieur et l'intérieur du contour (cas mono cible) sont prises en compte dans l'estimation de la forme du contour ; cela permet d'extraire des formes dans des images où les contours de la cible sont mal définis, en raison d'un fort niveau de bruit par exemple. Les algorithmes découlant de cette approche n'ont fait l'objet, à notre connaissance, d'aucune parallélisation sur GPU, malgré le grand intérêt qu'elles revêtent dans l'interprétation d'images fortement bruitées (RADAR, médicales, . . .) et le besoin d'en réduire les temps d'exécution suffisamment pour permettre l'interactivité. Nous proposons dans la suite de ce chapitre de détailler tout d'abord l'algorithme séquentiel que nous avons pris comme référence, puis d'en présenter la version parallèle pour GPU que nous en avons conçu. L'algorithme a été décrit et proposé initialement en 1999 par Chesnaud *et al.* dans [24]. L'implémentation que les auteurs ont développé a continué d'être améliorée jusqu'à aujourd'hui et est employée comme brique élémentaire dans des algorithmes plus complexes. La version qui sert de référence ici est une implémentation séquentielle optimisée qui met aussi à profit les capacités de parallélisme des CPU actuels en employant le jeu d'instruction SSE2 des microprocesseurs. La description que nous en faisons dans les lignes qui suivent est très largement inspirée de [24] à la différence que nous n'implémentons pas les critères de régularisation du contour ni de minimisation de la longueur de description pour nous focaliser sur la déformation du contour et sa convergence.

4.1.1/ FORMULATION

À l'intérieur de l'image observée \bar{v} , soient \bar{t} le vecteur composé par les niveaux de gris des N_t pixels de la région cible Ω_t et \bar{b} celui des N_b pixels du fond Ω_b . Les vecteurs \bar{t} et \bar{b} sont supposés non corrélés et sont caractérisés par leurs densités de probabilité (PDF) respectives p^{Θ_t} et p^{Θ_b} ; Θ_t et Θ_b étant les vecteurs des paramètres de leurs PDF. Dans le cas gaussien que nous supposons ici, $\Theta = (\mu, \sigma)$ où μ est la moyenne et σ^2 est la variance. On note Γ le contour de la région cible ($\Gamma \in \Omega_t$), que l'on suppose continu en connexité à 8 voisins.

Le but de la segmentation est alors de déterminer la géométrie de Γ qui maximise un critère de vraisemblance généralisée (GL). La vraisemblance sur l'ensemble de l'image, *ie.* la région Ω est donnée par

$$P(\bar{v}|\Omega_t, \Omega_b, \Theta_t, \Theta_b) = P(\bar{v}|\Omega_t, \Theta_t) P(\bar{v}|\Omega_b, \Theta_b) \quad (4.1)$$

soit en développant

$$P(\bar{v}|\Omega_t, \Omega_b, \Theta_t, \Theta_b) = \prod_{x_k \in \Omega_t} p^{\Theta_t}(v_k, \Theta_t) \prod_{x_k \in \Omega_b} p^{\Theta_b}(v_k, \Theta_b) \quad (4.2)$$

Dans le cas gaussien, la PDF étant de la forme

$$p(\alpha) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(\alpha-\mu)^2}{2\sigma^2}} \quad (4.3)$$

La substitution de (4.3) dans (4.2), suivie du logarithme, permet d'obtenir l'expression de la *log-vraisemblance*

$$-N_t \ln(\sqrt{2\pi}) - N_t \ln(\sigma_t) - \frac{1}{2\sigma_t^2} \sum_{x_k \in \Omega_t} (v_k - \mu_t)^2 - N_b \ln(\sqrt{2\pi}) - N_b \ln(\sigma_b) - \frac{1}{2\sigma_b^2} \sum_{x_k \in \Omega_b} (v_k - \mu_b)^2 \quad (4.4)$$

dans laquelle les vecteurs Θ_t et Θ_b sont estimés suivant la méthode du maximum de vraisemblance, qui donne l'expression générique suivante pour l'estimée de Θ_t , notée $\widehat{\Theta}_t$ et transposable à l'identique pour Θ_b

$$\widehat{\Theta}_t \begin{cases} \widehat{\mu}_t = \frac{1}{N_t} \sum_{x_k \in \Omega_t} v_k \\ \widehat{\sigma}_t^2 = \frac{1}{N_t} \sum_{x_k \in \Omega_t} (v_k - \widehat{\mu}_t)^2 \end{cases} \quad (4.5)$$

En intégrant (4.5) dans (4.4), il reste, à une constante près, le critère de vraisemblance généralisée suivant, noté GL, que l'on cherche à optimiser en déterminant la géométrie de Γ qui en maximise la valeur et épousera alors au mieux la forme du contour de la cible.

$$GL = \frac{1}{2} \left(N_t \ln(\widehat{\sigma}_t^2) + N_b \ln(\widehat{\sigma}_b^2) \right) \quad (4.6)$$

4.1.2/ OPTIMISATION DES CALCULS

La maximisation de GL est effectuée en employant une technique itérative où sa valeur doit être calculée à chaque déformation du contour Γ . Si l'on se reporte à l'équation (4.5), on voit que l'obtention de la valeur de GL nécessite, à chaque évaluation d'une géométrie donnée de Γ , le calcul des sommes

$$\begin{aligned} S_v(\Omega_t) &= \sum_{x_k \in \Omega_t} v_k & S_{v^2}(\Omega_t) &= \sum_{x_k \in \Omega_t} v_k^2 \\ S_v(\Omega_b) &= \sum_{x_k \in \Omega_b} v_k & S_{v^2}(\Omega_b) &= \sum_{x_k \in \Omega_b} v_k^2 \end{aligned} \quad (4.7)$$

Considérons la région cible Ω_t , les pixels de coordonnées (i, j) qui la composent, et généralisons l'écriture des sommes de (4.7) en

$$S_f(\Omega_t) = \sum_{i=i_{\min}}^{i=i_{\max}} \sum_{j=j_{\min}(i)}^{j=j_{\max}(i)} g(v(i, j)) \quad (4.8)$$

où f représente la fonction de valeurs de niveaux de gris à sommer.

En posant

$$T_g(y, \tau) = \sum_{j=0}^{\tau} g(v(y, j)) \quad (4.9)$$

L'équation (4.8) devient

$$S_f(\Omega_t) = \sum_{i=i_{\min}}^{i=i_{\max}} [T_g(i, j_{\max}(i)) - T_g(i, j_{\min}(i) - 1)] \quad (4.10)$$

qui représente une sommation sur le contour Γ que l'on peut écrire

$$S_f(\Omega_t) = \sum_{(i,j) \in \Gamma} C(i, j) \gamma(i, j) \quad (4.11)$$

où $C(i, j)$ est un coefficient lié à la direction du contour au point (i, j) et $\gamma(i, j)$ prend sa valeur selon les règles suivantes

$$\gamma(i, j) = \begin{cases} T(i, j) & \text{si } C(i, j) = 1 \\ T(i, j - 1) & \text{si } C(i, j) = -1 \\ 0 & \text{si } C(i, j) = 0 \end{cases} \quad (4.12)$$

La valeur de $C(i, j)$ est déterminée pour chaque pixel d'indice l du contour en considérant les pixels d'indices $l - 1$ et $l + 1$ qui définissent les deux vecteurs f_{in} et f_{out} et leur code selon le codage de Freeman, comme l'illustre la figure 4.1. La table 4.1 donne les valeurs de $C(i, j)$ selon les valeurs des codes de Freeman des vecteurs f_{in} et f_{out} . Il faut noter que les valeurs dans la table 4.1 diffèrent de celles proposées initialement dans [24]. Cette modification a été proposée plus tard pour permettre de s'adapter à la segmentation multi-cibles. Nous avons conservé la version la plus récente.




FIGURE 4.1 – À gauche : détermination des vecteurs f_{in} et f_{out} . À droite : code de Freeman d'un vecteur en fonction de sa direction, l'origine étant supposée au pixel central, en noir.

L'intérêt de cette transformation est majeur :

- La sommation en deux dimensions sur la région Ω_t est ainsi réduite à une sommation à une dimension sur le contour Γ .

f_{in}	f_{out}							
	0	1	2	3	4	5	6	7
0	0	0	0	0	0	-1	-1	-1
1	1	1	1	1	1	0	0	0
2	1	1	1	1	1	0	0	0
3	1	1	1	1	1	0	0	0
4	0	0	0	0	0	-1	-1	-1
5	0	0	0	0	0	-1	-1	-1
6	0	0	0	0	0	-1	-1	-1
7	0	0	0	0	0	-1	-1	-1

TABLE 4.1 – Valeur du coefficient $C(i, j)$ en fonction des valeurs des codes de Freeman des vecteurs f_{in} et f_{out} .

- Les valeurs $T_g(i, j)$ peuvent être calculées préalablement à la phase de segmentation proprement dite. Pour le cas gaussien qui nous intéresse, cela revient à pré-calculer les trois images *cumulées* S_1 , S_x et S_{x^2} définies par

$$S_1(i, j) = \sum_{x=0}^j x \quad , \quad S_x(i, j) = \sum_{x=0}^j v(i, x) \quad \text{et} \quad S_{x^2}(i, j) = \sum_{x=0}^j v(i, x)^2 \quad (4.13)$$

- Les valeurs du coefficient $C(i, j)$ se calculent très facilement durant la génération du contour Γ .

Par ailleurs, le choix d'un contour polygonal permet également d'améliorer l'efficacité de l'algorithme car lors de la phase de segmentation, le déplacement d'un sommet du polygone n'influe que sur les pixels des deux segments qui s'y rapportent, réduisant ainsi la quantité de calculs à effectuer à chaque nouvelle déformation du contour.



L'approche décrite dans ce chapitre n'est valide que si les segments formant le polygone du contour ne se croisent pas. Il est donc nécessaire, lors de la convergence de la segmentation, d'empêcher les croisements de segments. Une solution simple a été proposée dans [24] et nous l'avons parallélisée dans le cadre des travaux présentés ici.

4.1.3/ IMPLÉMENTATION SÉQUENTIELLE

Un des inconvénients des algorithmes de type *snake* est l'influence du contour initial sur la convergence de la segmentation. Pour pallier simplement ce défaut, une technique progressive est adoptée, en initialisant le contour avec peu de sommets (4) puis en augmentant le nombre au fur et à mesure de la convergence. L'algorithme ?? décrit macroscopiquement la solution mise œuvre tandis que l'algorithme ?? en présente les détails.

Les différentes sommations nécessaires au calcul de la valeur du critère GL sont effectuées en parallèle à l'aide du jeu d'instructions SSE2. La taille des registres utilisables

Algorithme 2 : Principe mis en œuvre pour la convergence du snake polygonal

```

1 Calculer les images cumulées;
2 Initialiser le contour avec 4 sommets;
3 répéter /* niveau contour */
4   | répéter /* niveau sommet */
5   |   | Déplacer chaque sommet autour de sa position actuelle.;
6   |   | Déplacer le sommet vers la position induisant le meilleur GL;
7   |   | jusqu'à aucun sommet ne peut être déplacé;
8   |   | Ajouter un sommet au milieu de chaque grand segment;
9 jusqu'à aucun sommet ne peut être ajouté;

```

est de 128 bits et permet ainsi de traiter des images de 4096×4096 pixels dont les niveaux de gris sont codés sur 16 bits. Cela ne laisse toutefois que 12 bits pour le codage des segments du contour et limite ainsi leur longueur à 4096 pixels. L'organisation d'un registre SSE 128 bits est donc la suivante :

- 24 bits pour les sommes à opérandes dans S_1
 - $24+16 = 40$ bits pour les sommes à opérandes dans S_x
 - $24+32 = 60$ bits pour les sommes à opérandes dans S_x^2
- Soit un total de 124 bits, qui peuvent donc être représentés par un registre SSE2.

4.1.4/ PERFORMANCES

Les images de 1024^2 pixels de la figure 4.2 montrent l'évolution du contour lors de la segmentation d'une image photographique prise en faible éclaircissement et bruitée artificiellement par un bruit gaussien d'écart type 25. Les paramètres de la séquence sont fixés empiriquement aux valeurs $d_{max} = 16, l_{min} = 8$. Les temps d'exécution indiqués sont mesurés sur Intel Xeon E5530-2.4GHz with 12Go RAM et sont les valeurs moyennes obtenues pour 10 exécutions.

La dépendance vis à vis du contour initial qui est un des principaux soucis liés au snake est ici fortement relativisée. La figure 4.3 montre le contour final segmentant l'image de test de la figure 4.2 à partir d'un état initial très éloigné du précédent et *a priori* très défavorable compte tenu du fait qu'il est loin de la cible et sans intersection avec elle. Toutefois, le contour final obtenu est très proche de celui obtenu à partir d'un état initial englobant la cible, malgré un nœud qui s'est "accroché" au bord de l'image. La convergence est également plus longue à obtenir dans ce cas avec un total de 17 itérations en 87 ms et 273 nœuds.

La dimension de l'image à traiter a également un effet sur le résultat et naturellement sur le temps de calcul. Si l'on conserve les mêmes paramètres d'optimisation que pour la segmentation de l'image 512^2 pixels et un contour initial dont les cotés sont à une distance des bords équivalente à 10% des cotés de l'image, le résultat sur une image identique de 4000^2 pixels est obtenu en 1.3 s avec 1246 nœuds ; il est reproduit à la figure 4.4(a). Le nombre de pixels appartenant à la région cible est tel que l'amplitude des déplacements autorisés pour chaque nœud (d) peut se révéler trop faible vis à vis du seuil d'acceptation des mouvements. On observe que les zones à gradient élevé ne posent pas de problème et sont détournées de la même manière, alors que dans le bas de l'image où figure une zone de gradient faible (ombre), la cible se trouve maintenant quelque peu




FIGURE 4.2 – Évolution du contour lors de la segmentation d'une image de 512^2 pixels. La convergence est obtenue à l'itération 14 après 44 ms pour un total de 256 nœuds.

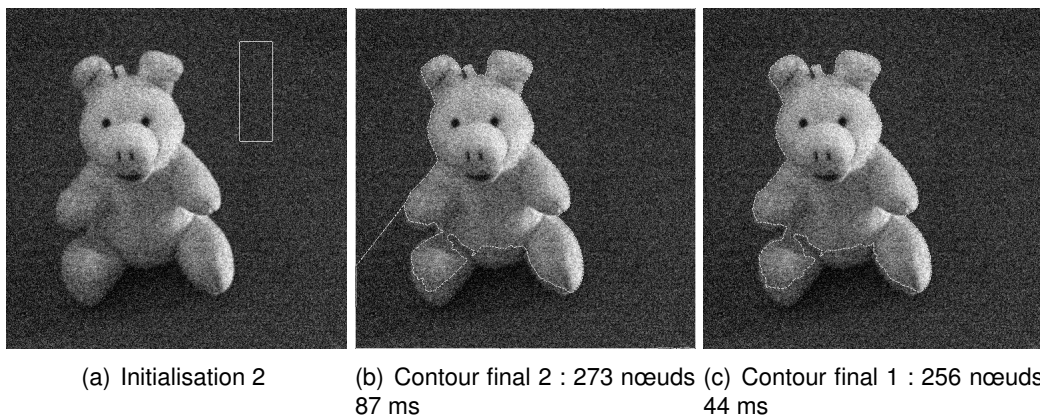




FIGURE 4.3 – Influence du contour initial sur la segmentation. Le contour final 1 est celui de la figure 4.2.

FIGURE 4.4 – Segmentation de l'image de test en 4000^2 pixels.

surévaluée en surface là où elle était plutôt sous évaluée dans l'image en 512^2 pixels. On parvient à un résultat très proche beaucoup plus rapidement en adaptant les paramètres à la taille de l'image, comme le montre par exemple la segmentation de la figure 4.4(b), effectuée avec $d_{max} = 128$ et $l_{min} = 32$ et qui converge vers un contour de 447 nœuds en moins de 0.7 s. Au delà des 16 millions de pixels (4000^2 pixels), l'implémentation séquentielle est toujours possible mais doit se priver des instructions SSE. Nous avons, avec leur accord, adapté le code des auteurs en ce sens et réalisé les mesures pour des tailles allant jusqu'à 150 MP. La table 4.2 en synthétise les résultats en distinguant chaque fois le temps pris par les pré-calculs et celui nécessaire à la convergence de la segmentation.

Enfin, il faut aussi considérer les tailles relatives de la cible et de l'image. Ainsi, si on fait l'hypothèse d'une cible de petite taille "noyée" dans une image de grandes dimensions, les résultats de la segmentation seront impactés en raison, cette fois, d'une moindre adaptation à la cible lors des toutes premières itérations, les plus grossières, où le nombre de nœuds est réduit et le pas de déplacement potentiellement grand vis à vis de la cible. Ce cas de figure est illustré par la segmentation reproduite à la figure 4.5 et qui met en évidence une qualité moindre par la confusion des zones les plus sombres de la cible avec le fond.

FIGURE 4.5 – Segmentation de l'image de test en 4000^2 pixels avec une cible de petite taille. Le contour initial est celui utilisé à la figure 4.4.




FIGURE 4.6 – Évolution du coût relatif des trois fonctions les plus consommatrices en temps de calcul en fonction de la taille de l'image à traiter.

4.2/ IMPLÉMENTATION PARALLÈLE GPU DU SNAKE POLYGONAL

L'analyse de l'exécution du programme séquentiel révèle la prépondérance des blocs fonctionnels suivants, dans l'ordre d'importance, qui occupent à eux seuls plus de 80% du temps total d'exécution :

- Le calcul de la contribution des segments (lignes 19 à 21 dans l'algorithme 3)
- La génération des trois images cumulées, avant le début des itérations (ligne 2).
- La discrétisation des segments définis par les coordonnées de leurs extrémités (ligne 18).

Cette proportion est globalement conservée lorsque la taille de l'image à traiter varie, comme le montre le graphique de la figure 4.2

Si l'effort de parallélisation porte essentiellement sur ces fonctions coûteuses, l'ensemble du traitement est réalisé sur le GPU afin de réduire autant que possible les transferts entre le GPU et le système hôte qui, selon le volume concerné, sont susceptibles de grever considérablement la performance globale. L'hôte ne conserve que l'initiative du transfert initial et le contrôle de la boucle principale, ne nécessitant l'échange que d'un seul octet à chaque itération (le nombre de nouveaux nœuds N_{add}).

Les traitements étant totalement indépendants, nous traitons séparément la parallélisation des pré-calculs et celle de la segmentation.

4.2.1/ PRÉ-CALCULS DES IMAGES CUMULÉES

Pour réduire la quantité de mémoire requise, nous avons choisi de ne pas générer l'image S_1 mais plutôt d'en calculer les valeurs à la volée. L'expression en est simple et le temps pris par les opérations élémentaires qu'elle met en jeu est largement compensé par le gain obtenu en économisant les accès mémoire qui auraient été nécessaires, ce qui n'est pas le cas des deux autres images S_x et S_x^2 dont le calcul est quant à lui réalisé en appliquant la méthode des *prefixsums* décrite dans [10].

Les sommations se font au niveau de chaque ligne de l'image, que l'on décompose en n blocs de b_s pixels où b_s correspond aussi au nombre de threads exécutés par chaque bloc de la grille de calcul. La valeur b_s étant obligatoirement une puissance de 2 supérieure à 32, le bloc de pixels d'indice $n - 1$ doit éventuellement être complété par des valeurs nulles. Chaque bloc de thread réalise son traitement indépendamment des autres, mais l'ensemble des sommes de bloc étant requise pour le calcul des sommes globales, une

synchronisation est nécessaire à deux endroits du calcul. Nous avons choisi d'assurer ces synchronisations en découpant le traitement en trois *kernels* distincts, rendant par la même occasion le code plus concis :

- `compute_block_prefixes()` est le *kernel* effectuant, en mémoire partagée, les prefixsums inclusif de chaque bloc, puis mémorisant les sommes des blocs, *i.e* le dernier élément du prefixsum associé, dans deux vecteurs V_x et V_x^2 en mémoire globale. L'ensemble des prefixsums est également mémorisé en mémoire globale. La largeur de l'image n'étant pas nécessairement une puissance de 2, il est nécessaire de faire du remplissage avec des valeurs nulles dans le dernier bloc (indice $n - 1$).
- `scan_blocksums()` est le *kernel* effectuant les prefixsum exclusifs des vecteurs V_x et V_x^2 . Les résultats demeurent respectivement dans V_x et V_x^2 .
- `add_sums2prefixes()` est le *kernel* effectuant les additions de chaque élément d'indice i des vecteurs V_x (respectivement V_x^2 avec tous les éléments du prefixsum du bloc de même indice i associé).

Les diagrammes de la figure 4.2.1 donnent le détail des opérations effectuées par ces trois *kernels* pour l'image cumulée S_x . La seconde image cumulée S_x^2 est obtenue exactement de la même manière en sommant non plus les valeurs v_k mais v_k^2 .

Les gains de performance de cette implémentation GPU comparée à l'implémentation CPU/SSE2 sont ceux de la table 4.3, soit un GPU environ 7 fois plus rapide pour des images de taille 15 à 150 millions de pixels. L'influence de la taille d'image sur le gain est faible, mais on peut toutefois noter que plus l'image est grande plus le gain est important. On obtient des accélérations supérieures en rendant le calcul moins générique et en développant des versions spécifiques des trois *kernels*, dédiées par exemple au traitement des images dont la largeur est multiple de 256 pixels.

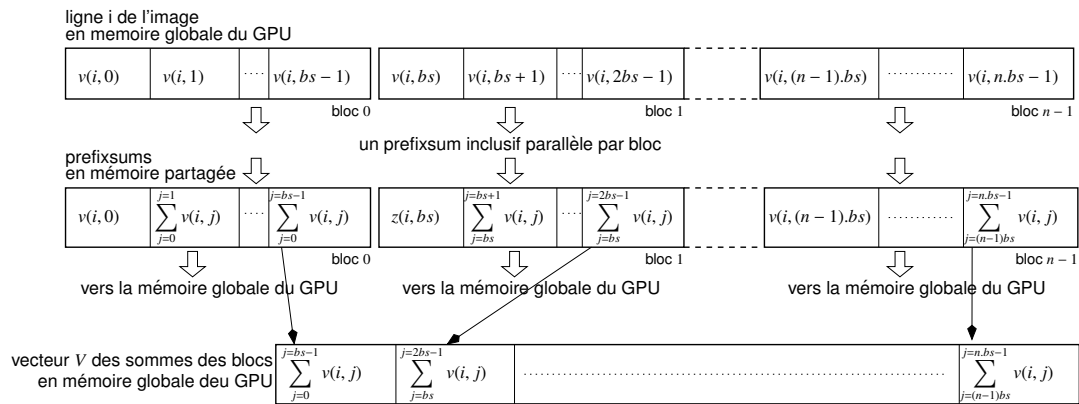
4.2.2/ CALCUL DES CONTRIBUTION DES SEGMENTS

Le déplacement d'un des N_n nœuds du contour Γ vers l'une des 8 positions voisines permises, impose d'évaluer les contributions des 8 paires de segments associées, soit $16N_n$ segments pour la totalité du contour, que nous évaluons en parallèle au sein du *kernel* `GPU_compute_segments_contribs()`. Pour ce faire, chaque segment doit tout d'abord être discrétisé en une suite de pixels puis, en conservant la règle *1 pixel par thread* la contribution de chaque pixel est déterminée avant de toutes les additionner pour obtenir la contribution du segment. Les pixels représentant les nœuds font l'objet d'un traitement spécifique impliquant les codes de Freeman, pour ne pas fausser les contributions globales (voir paragraphe 4.1.3).


Pour optimiser l'exécution de ce *kernel* et réduire l'effet de la disparité des longueurs des segments, nous créons un motif régulier en mémoire, basé sur la longueur $npix_{max}$ du plus grand segment et moyennant le recours au remplissage par des valeurs neutres là où c'est nécessaire pour les autres segments.

Si bs_{max} est la taille de bloc maximale admissible par le GPU, la taille bs des blocs de threads/pixels employée pour le calcul des contributions des segments est alors déterminée de la façon suivante :

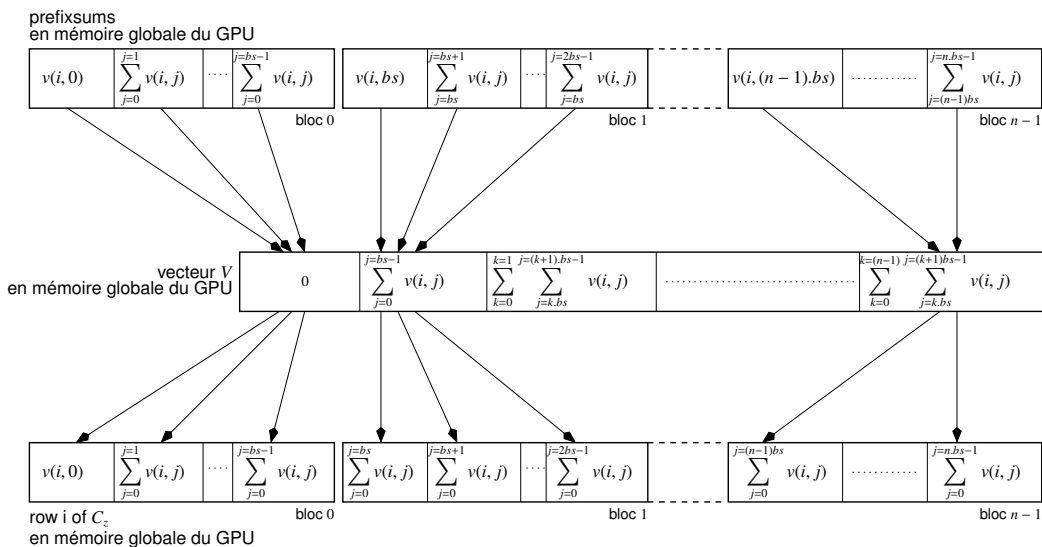
$$bs = \begin{cases} 2^p & \text{avec } 2^{p-1} < npix_{max} \leq 2^p \text{ si } npix_{max} \in [33; bs_{max}] \\ 32 & \text{si } npix_{max} \leq 32 \\ bs_{max} & \text{si } npix_{max} > bs_{max} \end{cases}$$



(a) Détail des opérations effectuées par le *kernel* `compute_block_prefixes()`. La valeur bs correspond au nombre de pixels de chaque bloc, qui est aussi le nombre de threads exécuté par chaque bloc de la grille de calcul.



(b) Détail des opérations effectuées par le *kernel* `scan_blocksums()`.



(c) Détail des opérations effectuées par le *kernel* `add_sums2prefixes()`.

FIGURE 4.7 – Calcul des images cumulées S_x et S_x^2 en trois étapes successives. a) cumul partiel bloc par bloc et mémorisation de la somme de chaque bloc. b) cumul sur le vecteur des sommes partielles. c) ajout des sommes partielles à chaque élément des blocs cumulés.




FIGURE 4.8 – Structuration des données en mémoire du GPU pour l'évaluation en parallèle de l'ensemble des évolutions possibles du contour.

Dans notre implémentation, les calculs sont faits en mémoire partagée et la quantité nécessaire limite la taille de bloc admissible. Nous limitons celle-ci à 256 sur C1060 et 512 sur C2050. Toutefois, les tests ont montré que sur ces deux versions de l'architecture, la taille maximale conduisant aux meilleures performances est de 256 threads par bloc.

Le *kernel* `GPU_compute_segments_contribs()` calcule alors en parallèle pour tous les segments les coordonnées de tous les pixels qui les composent. Nous mettons pour cela en œuvre l'algorithme de Bresenham, *i.e* la méthode du segment semi-ouvert, en distinguant les cas où

- la valeur absolue de la pente k du segment à discrétiser est supérieure à 1 ; on applique alors la méthode au segment *horizontal* semi-ouvert et on obtient un pixel par ligne.
- la valeur absolue de la pente k du segment à discrétiser est inférieure ou égale à 1 ; on applique alors la méthode au segment *vertical* semi-ouvert et on obtient un pixel par colonne.

Cette distinction nous permet de conserver la règle *1 pixel par thread* importante pour la régularité des motifs d'accès en mémoire et aussi pour *charger* au maximum le GPU.

La figure 4.2.2 représente la structure décrite ci-dessus pour la représentation en mémoire des segments à évaluer. La première ligne montre le détail du premier segment, avec la correspondance *1 pixel par thread* et le découpage en un nombre de blocs suffisant pour permettre de décrire le plus long des segments.

La seconde ligne présente l'ordre dans lequel sont concaténés les 16 groupes de blocs-segment associés au déplacement d'un nœud particulier.

Aux deux dernières lignes est décrite la concaténation des ensembles de 16 blocs-segment, avec la particularité de séparer la description des nœuds d'indices pairs et ceux d'indices impairs. Cela permet de moins s'écarter de l'heuristique d'optimisation en vigueur dans la version séquentielle : les statistiques globales comme la valeur de critère GL y sont recalculées après chaque déplacement, alors que dans le cas d'un traitement

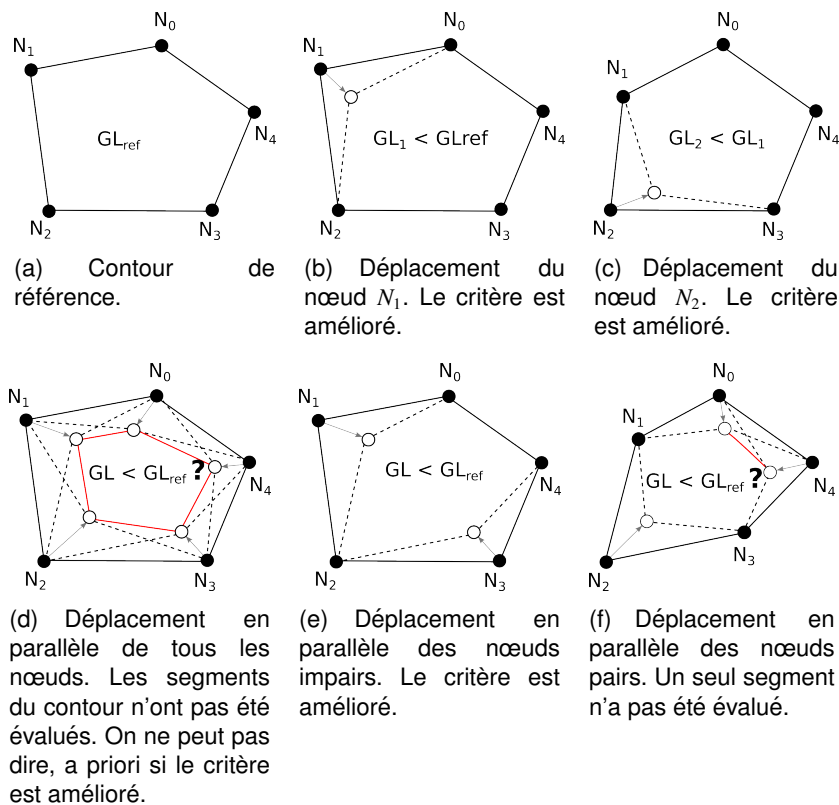


FIGURE 4.9 – Comparaison des cycles de déplacement des nœuds. Ligne du haut : version séquentielle. Ligne du bas : version parallèle. Les segments en rouge sont des segments du contour non évalués, alors que ceux en pointillés sont les paires ayant reçu les meilleures évaluations parmi les 8 déplacements possibles des nœuds correspondant.

parallèle, les statistiques de référence ne sont calculées qu'après le déplacement simultané des N_n nœuds ; les résultats et la convergence en sont potentiellement affectés, comme l'illustrent les situations présentées à la figure 4.2.2, car les segments composant véritablement le contour après déplacement des nœuds n'ont pas nécessairement été évalués (segments en rouge dans la figure 4.2.2).

La représentation en mémoire des segments conduit à avoir un certain nombre non prévisible de threads inactifs dans la grille, sans que cela soit préjudiciable aux performances car cela n'engendre pas de branches divergentes.

Les calculs liés à l'évaluation des contributions des pixels sont réalisés en mémoire partagée. Seule une très petite quantité de données doit être stockée en mémoire globale. Il s'agit, pour chaque segment (pas pixel) :

- des coordonnées de son milieu. Cela permet l'ajout efficace quand c'est nécessaire.
- les coordonnées des deux derniers pixels de chaque extrémité. Ils sont nécessaires pour calculer la dérivée aux extrémités et ainsi déterminer le code de Freeman des nœuds.

Pour obtenir les contributions des segments, *i.e* les sommes des contributions des leurs pixels, une première phase de réduction partielle est effectuée au niveau de chaque bloc.

Une synchronisation est alors nécessaire avant d'effectuer les sommes de l'ensemble des contributions partielles qui fournissent les contributions globales des segments. Le

contour modifié est alors construit comme la suite des meilleures positions déterminées pour chaque nœud, pour peu que ces nouvelles positions ne génèrent pas de croisement de segments.

La solution retenue pour vérifier l'absence de croisement est celle de l'implémentation séquentielle, parallélisée simplement par paire de segments. Cela n'apporte pas de véritable gain de performance par rapport à la version CPU, mais contraints de conserver les données en mémoire GPU pour limiter les transferts entre l'hôte et son périphérique, nous avons tâché de faire en sorte que cette fonctionnalité ne grève pas les performances globales.

Les calculs des statistiques globales du nouveau contour et du critère GL sont effectués après l'obtention du nouveau contour. Les valeurs obtenues servent de référence pour les prochaines déformations du contour. Les techniques appliquées pour ces calculs sont de nouveau celles décrites au début ce paragraphe. Enfin l'ajout des nouveaux nœuds se fait simplement pour les segments suffisamment grands, en utilisant les coordonnées des pixels milieux mémorisées lors de la discrétisation des segments.

4.2.2.1/ CAS PARTICULIER DES SEGMENTS DONT LA PENTE k VÉRIFIE $|k| \leq 1$

Comme nous venons de le voir, les segments dont la pente k vérifie $|k| \leq 1$ sont discrétisés à raison de *1 pixel par colonne* et comportent donc le plus souvent plusieurs pixels sur une ligne donnée, comme le montrent les schémas de la figure 4.2.2.1. D'après la formulation générale du snake faite au paragraphe 4.1.2, le coefficient $C(i, j)$ est à appliquer en chaque point du contour. La technique de discrétisation employée conduit à des coefficients $C(i, j)$ constants sur l'ensemble des pixels des segments dont la pente k vérifie $|k| > 1$, mais ce n'est pas le cas pour ceux dont la pente k est inférieure ou égale à 1. Les quatre cas, un par quadrant, qui peuvent se présenter sont représentés à la figure 4.2.2.1.

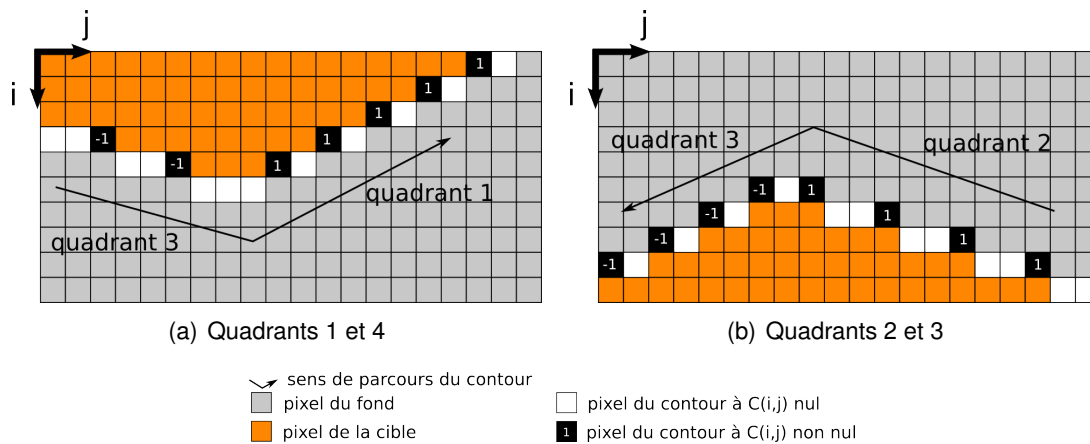
D'un point de vue opérationnel, on constate en se reportant à la table 4.1, que tout pixel dont les voisins immédiats sont sur la même ligne à un coefficient $C(i, j) = 0$ ($F_{in} = f_{out} = 0$). Les deux pixels des extrémités, n'ayant quant à eux qu'un voisin sur la même ligne, ont un coefficient qui dépend du quadrant :

- dans les quadrant 1 et 2
 - le premier pixel d'une ligne a un coefficient $C(i, j) = 1$.
 - le dernier pixel d'une ligne a un coefficient $C(i, j) = 0$
- dans les quadrant 3 et 4
 - le dernier pixel d'une ligne à un coefficient $C(i, j) = -1$.
 - le premier pixel d'une ligne a un coefficient $C(i, j) = 0$.

Les accès en mémoire, dans les images cumulées, aux contributions des pixels de coefficient $C(i, j) = 0$ sont évités et une contribution nulle leur est automatiquement attribuée dès l'étape de discrétisation au sein du kernel `GPU_compute_segments_contribs()`.

4.2.3/ PERFORMANCES

Dans l'hypothèse la plus contraignante d'images en niveaux de gris codés sur 16 bits, l'implémentation parallèle que nous venons de décrire utilise de manière permanente 20 octets par pixel de l'image d'entrée, qui se détaillent en

FIGURE 4.10 – Détermination des coefficients $C(i, j)$ des pixels du contour.

- l'image d'entrée pour 4 octets par pixel (1 entier).
 - l'image cumulée S_x pour 8 octets par pixel (1 entier long)
 - l'image cumulée S_x^2 pour 8 octets par pixel (1 entier long)
- auxquels il faut ajouter un maximum d'environ 50 Mo d'espace nécessaire à la mémorisation des variables temporaires des calculs et données diverses comme le contour lui-même (nœuds, milieux, Freemans, etc.).

Sur un GPU de type C1060 disposant de 3 Go de mémoire, cela permet de traiter des image jusqu'à presque 150 millions de pixels. Il est possible de réduire cette empreinte jusqu'à 13 octets par pixel, mais cela soulève la question de l'alignement des données en mémoire qui est sans objet en employant les type entier et entier long (32 et 64 bits) pour la représentation des données et qui permet de préserver les performances maximales des opérations et accès aux données du GPU. On pourrait tout de même porter ainsi la limite de taille de l'image d'entrée à 230 millions de pixels.

La convergence de notre implémentation intervient en un nombre généralement plus réduit d'itérations vers un contour final qui diffère par essence de celui obtenu avec la solution de référence. Ces effets sont la conséquence déjà abordée de l'heuristique d'optimisation appliquée à l'implémentation parallèle qui conduit à l'adoption de certains segments non évalués au préalable (voir fig. 4.2.2).

Les comparaisons visuelle et de valeur du critère GL qui peuvent être faites pour les images de taille inférieure à 4000^2 pixels nous renseignent toutefois sur la qualité de la segmentation obtenue. Pour les tailles au delà et jusqu'au maximum de 12000^2 pixels, le comportement est globalement conservé, mais on note qu'il n'est pas pertinent de permettre des tailles de segments trop petites vis à vis de la taille d'image, les déplacements des nœuds ne générant alors plus de variations significatives des contributions correspondantes.

La figure 4.2.3 présente deux segmentations effectuées sur des images de respectivement 100 et 150 millions de pixels alors que la table 4.4 résume les performances obtenues sur l'image du *cochon* en différentes tailles.




FIGURE 4.11 – Segmentations de grandes images, avec le contour initial transposé de celui de la figure 4.2. a) image de 100 MP. b) image de 150 MP.

4.2.4/ DISCUSSION SUR L'INITIALISATION

Nous avons déjà discuté de l'influence du contour initial sur le résultat de la segmentation, mais il faut ajouter que la durée d'exécution est aussi impactée par le choix du contour initial, dans des proportions qui peuvent être importantes selon la distance, la taille et dans une moindre mesure la forme de la cible.

Ces effets se mesurent lors de la première itération, celle qui va cerner grossièrement la cible avec un polygone à quatre cotés. Si le contour initial se trouve très éloigné, comme dans la situation de la figure 4.5, notre choix maintenant habituel d'un rectangle près des bords de l'image s'avère peu adapté et conduit à une première itération très longue. Dans un tel cas, pour une image de 10000^2 pixels, si la cible est un carré de 1000^2 pixels dont le sommet du bas à droite se confond avec celui du contour et que l'on approche par pas de 64 pixels, on devra dans le meilleur des cas déplacer les 4 nœuds du contour 110 fois de suite avant de pouvoir passer à la deuxième itération. Un pas de 128 permet de réduire ces valeurs, mais l'expérience montre qu'au delà, l'approche initiale de la cible est trop grossière et les itérations suivantes en pâtissent pour un résultat souvent dégradé. En revanche, si les proportions sont celles de la figure 4.2, seules 31 passes de déplacement des 4 nœuds initiaux sont nécessaires.

Pour optimiser l'initialisation, nous avons donc proposé de tirer parti du GPU pour évaluer une grande quantité de contours initiaux rectangulaires et réduire ainsi le coût de la première itération. Pour pouvoir employer la mémoire partagée comme tampon de données, il faut limiter le nombre de contours à évaluer. Nous avons donc effectué un échantillonnage spatial des images et déterminé le contour initial en deux temps, en mettant à profit la propriété qu'ont les segments horizontaux d'avoir une contribution nulle. Le principe mis en œuvre, illustré par la figure 4.2.4 est le suivant :

1. on réalise un échantillonnage horizontal pour ne considérer que les colonnes d'indice $j = 8k$.
2. on évalue alors tous les contours rectangulaires de diagonale $(0, j_L) - (j_H, H)$
3. on identifie le contour présentant le meilleur critère GL , ce qui détermine j_L et j_H .
4. on fait de même en échantillonnant verticalement : les lignes d'indice $i = 8t$ permettent de décrire tous les contours de diagonale $(i_L, j_L) - (i_H, j_H)$. Le meilleur

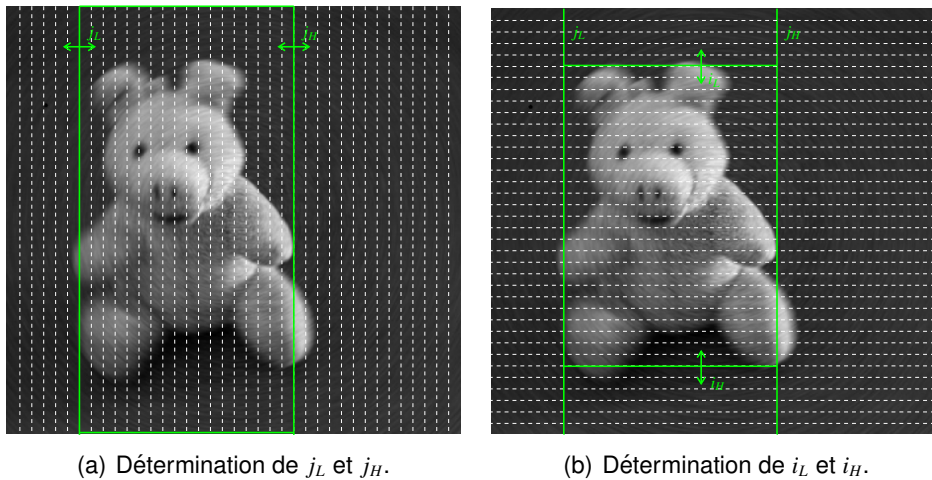


FIGURE 4.12 – Détermination intelligente du contour initial en deux phases successives. a) La première étape repose sur un échantillonnage horizontal. b) La seconde étape repose sur un échantillonnage vertical.

contour est celui retenu pour l'initialisation de la segmentation.

4.2.5/ CONCLUSION

Nous avons conçu une implémentation parallèle de *snake* polygonal orienté régions, ce qui à notre connaissance n'avait encore pas été réalisé, aucune publication n'étant parue à ce sujet.

Les objectifs étaient d'étendre les capacités de traitement de l'implémentation CPU de référence en terme de taille d'image en conservant des temps d'exécution acceptables ce qui, de l'avis des auteurs de la version CPU, impose de se situer *a minima* sous la seconde pour pouvoir envisager l'intégration dans une application interactive.

Sur ce point, les performances de notre version sont satisfaisantes, puisque nous avons repoussé la limite de taille de 16 à 150 millions de pixels et parvenons à segmenter ces grandes images en moins d'une seconde. Le temps de calcul dépend très fortement du contenu de l'image et la segmentation est le plus souvent obtenue en un temps plus court, mais il n'est pas impensable que certaines situations particulières puissent conduire à dépasser cette barre symbolique.

L'emploi du GPU dans notre implémentation ne parvient pas à être optimal car, par essence, la répartition des pixels d'intérêt est mouvante et ne permet pas de construire des accès coalescent à la mémoire. Les opérations de type réduction sont également nombreuses et ne sont pas les plus efficaces sur GPU. Dans notre situation, elles peuvent même représenter une perte de performances car effectuées sur des vecteurs de tailles insuffisantes pour que le GPU surclasse le CPU.

S'il s'agit de parler d'accélération, notre implémentation divise les temps de traitement précédents par un facteur allant de 6 à 15 selon l'image et le contour initial adopté. Rappelons encore que l'implémentation CPU de référence n'est pas une implémentation naïve, mais une solution optimisée employant déjà les capacités de parallélisme des microprocesseurs modernes et représentant *l'état de l'art* du domaine ; il n'était pas

trivial d'en surpasser les performances, même avec un GPU.

Par nécessité, notre solution s'écarte cependant quelque peu de l'algorithme original pour permettre les déplacements simultanés des l'ensemble des sommets du polygone. Ce faisant, la décroissance du critère n'est pas certaine à toutes les étapes de la segmentation et l'on observe cette conséquence en particulier lors des dernière itérations lorsque le pas de déplacement et aussi les variations du critère sont faibles. Ce comportement, lorsqu'il est observé, provoque parfois la convergence prématurée de la segmentation, mais n'influe toutefois que sur quelques nœuds et dans la mesure d'un pixel.

La technique que nous avons proposée pour la détermination du contour initial permet d'augmenter encore les performances, surtout dans les grandes images lorsque la cible est petite vis à vis des dimensions de l'image. Nous ne sommes pas parvenu à concevoir une technique permettant de prévoir si la recherche intelligente du contour initial serait génératrice de gain de performance.

L'analyse fine des séquences de segmentation montre enfin que les première étapes, qui mettent en œuvre les segments les plus longs, génèrent des grilles de calcul suffisamment chargées et homogènes pour présenter de bonnes performances. Les dernière étapes, en revanche, traitent d'une plus grand nombre de petits segments, générant beaucoup de trous dans la grille de calcul et induisant des performances moindres. L'accélération globale obtenue est ainsi généralement le fruit du calcul des images cumulées et des toutes premières étapes de déplacements. Une possibilité qui reste à explorer serait de construire une version hybride réalisant le début de la segmentation sur GPU, puis terminant sur le CPU hôte. Ceci est envisageable en raison du très petit volume de données à transférer que constituent les paramètres du contour (2 ko pour 100 nœuds).

Algorithme 3 : Détail de l'implémentation du snake polygonal

```

1 Lire l'image  $\bar{v}$ ;
2 Calculer les images cumulées  $S_1, S_x, S_{x^2}$ ;          /* en parallèle via SSE2 */
3  $n \leftarrow 0$ ;                                     /* indice de boucle niveau contour */
4  $N_n \leftarrow 4$ ;                                  /* nombre de nœuds */
5  $\Gamma \leftarrow \{\Gamma_0, \Gamma_1, \Gamma_2, \Gamma_3\}$ ;
6  $d \leftarrow d_{max}$ ;                               /* pas de déplacement des nœuds */
7  $l_{min} = 32$ ;                                     /* longueur mini des segments sécables */
8  $\Gamma_i \leftarrow \Gamma_0$ ;                       /* sommet courant */
9  $GL_{ref} \leftarrow GL(\Gamma, N_n, \bar{v}, S_y, S_{y^2})$ ; /* voir à partir de ligne 18 pour le détail */
10 répéter                                          /* niveau contour */
11      $N_{add} \leftarrow 0$ ;
12     répéter                                     /* niveau nœud */
13          $N_{move} \leftarrow 0$ ;
14         pour  $i = 0$  à  $i = N_n - 1$  faire
15             Calculer les positions  $\{\Gamma_i^0, \dots, \Gamma_i^7\}$ ; /* les 8 voisins de  $\Gamma_i$  */
16             pour  $w = 0$  à  $w = 7$  faire
17                 Soustraire à  $GL_{ref}$  la contribution des segments  $\Gamma_{i-1}\Gamma_i$  et  $\Gamma_i\Gamma_{i+1}$ ;
18                 Discrétiser les segments  $\Gamma_{i-1}\Gamma_i^w$  et  $\Gamma_i^w\Gamma_{i+1}$ ;
19                 Lire dans  $S_1, S_x$  et  $S_{x^2}$  les contributions des pixels de  $\Gamma_{i-1}\Gamma_i^w$  et  $\Gamma_i^w\Gamma_{i+1}$ ;
20                 Calculer les directions et lire les codes de Freeman ;
21                 Calculer  $GL_w$  incluant les contributions de  $\Gamma_{i-1}\Gamma_i^w$  et  $\Gamma_i^w\Gamma_{i+1}$  ;
22                 si  $GL_w > GL_{ref}$  alors  $GL_{ref} \leftarrow GL_w$ ;
23                  $\Gamma_i \leftarrow \Gamma_i^w$ ;
24                  $N_{move} \leftarrow N_{move} + 1$ ;
25             fin
26         fin
27          $l \leftarrow l + 1$ ;
28     jusqu'à  $N_{move} = 0$ ;
29     pour chaque segment  $\Gamma_i\Gamma_{i+1}$  faire
30         si  $\|\Gamma_i\Gamma_{i+1}\| > l_{min}$  alors
31             Ajouter un nœud au milieu de  $\Gamma_i$  et  $\Gamma_{i+1}$ ;
32              $N_{add} \leftarrow N_{add} + 1$ ;
33         fin
34     fin
35      $N_n \leftarrow N_n + N_{add}$ ;
36     si  $d > 1$  alors  $d \leftarrow d/2$  sinon  $d \leftarrow 1$  ;
37      $GL_{ref} \leftarrow GL(\Gamma, N_n, \bar{v}, S_y, S_{y^2})$ ;
38 jusqu'à  $N_{add} = 0$ ;

```

	Taille de l'image (millions de pixels)		
	15	100	150
Pré-calculs	0,13	0,91	1,4
Segmentation	0,46	3,17	4,3
Total	0,51	4,08	5,7

TABLE 4.2 – Performances (en secondes) de la segmentation par snake polygonal sur CPU en fonction de la taille de l'image à traiter. Le temps sont obtenus avec la même image de test dilatée et bruitée et un contour initial carré dont la distance aux bords est proportionnelle à la taille de l'image. Seule l'image en 15 MP a pu être traitée par une implémentation utilisant SSE2.

	Taille de l'image (millions de pixels)		
	15	100	150
temps CPU (s)	0,13	0,91	1,4
temps GPU (s)	0,02	0,13	0,2
Accélération	6,5	6,9	7,0

TABLE 4.3 – Accélération constatée, pour le calcul des images cumulées, de l'implémentation GPU par rapport à l'implémentation CPU de référence.

		Performances		
		CPU	GPU	CPU/GPU
Image 15 MP	total	0,51 s	0,06 s	x8,5
	images cumulées	0,13 s	0,02 s	x6,5
	segmentation	0,46 s	0,04 s	x11,5
Image 100 MP	total	4,08 s	0,59 s	x6,9
	images cumulées	0,91 s	0,13 s	x6,9
	segmentation	3,17 s	0,46 s	x6,9
Image 150 MP	total	5,70 s	0,79 s	x7,2
	images cumulées	1,40 s	0,20 s	x7,0
	segmentation	4,30 s	0,59 s	x7,3

TABLE 4.4 – Comparaison des temps d'exécution de l'implémentation GPU par rapport à l'implémentation CPU de référence, appliqués à une même image dilatée pour en adapter la taille.

LE FILTRAGE DES IMAGES SUR GPU

- 5.1/ ALGORITHME DE RÉDUCTION DE BRUIT PAR RECHERCHE DES LIGNES DE NIVEAUX
- 5.2/ FILTRE MÉDIAN
- 5.3/ FILTRES DE CONVOLUTION

CONCLUSION GÉNÉRALE

BIBLIOGRAPHIE

- [1] Kdd cup data, October 1999.
- [2] Ccd image sensor noise sources. Technical report, Eastman Kodak company, Rochester, August 2001.
- [3] David Adalsteinsson and James Sethian. *A fast level set method for propagating interfaces*. PhD thesis, University of California, 1994.
- [4] Pankaj K Agarwal and Cecilia Magdalena Procopiuc. Exact and approximation algorithms for clustering. *Algorithmica*, 33(2) :201–226, 2002.
- [5] M. Aldinucci, C.S.M. Drocco, M. Torquati, and S. Palazzo. A parallel edge preserving algorithm for salt and pepper image denoising. 2012.
- [6] Pablo Arbelaez, Michael Maire, Charless Fowlkes, and Jitendra Malik. Contour detection and hierarchical image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 33(5) :898–916, 2011.
- [7] Sanjeev Arora, Prabhakar Raghavan, and Satish Rao. Approximation schemes for euclidean k-medians and related problems. In *Proceedings of the thirtieth annual ACM symposium on Theory of computing*, pages 106–113. ACM, 1998.
- [8] Christian Bauer, Horst Bischof, and Reinhard Beichel. Segmentation of airways based on gradient vector flow. In *International workshop on pulmonary image analysis, Medical image computing and computer assisted intervention*, pages 191–201, 2009.
- [9] Nicolas Bertaux, Yann Frauel, Philippe Réfrégier, and Bahram Javidi. Speckle removal using a maximum-likelihood technique with isoline gray-level regularization. *JOSA A*, 21(12) :2283–2291, 2004.
- [10] Guy E. Blelloch. Prefix sums and their applications. Technical Report CMU-CS-90-190, School of Computer Science, Carnegie Mellon University, November 1990.
- [11] Yuri Boykov and Vladimir Kolmogorov. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 26(9) :1124–1137, 2004.
- [12] Jack E Bresenham. Algorithm for computer control of a digital plotter. *IBM Systems journal*, 4(1) :25–30, 1965.
- [13] A. Buades, B. Coll, and J. M Morel. A non-local algorithm for image denoising. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 2, pages 60–65 vol. 2, 2005.
- [14] Antoni Buades, Bartomeu Coll, and Jean-Michel Morel. The staircasing effect in neighborhood filters and its solution. *IEEE Transactions on Image Processing*, 15(6) :1499–1505, 2006.
- [15] Vicent Caselles and Jean michel Morel. Topographic maps and local contrast changes in natural images. *Int. J. Comp. Vision*, 33 :5–27, 1999.

- [16] Bryan Catanzaro, Bor-Yiing Su, N. Sundaram, Yunsup Lee, Mark Murphy, and K. Keutzer. Efficient, high-quality image contour detection. In *Computer Vision, 2009 IEEE 12th International Conference on*, pages 2381–2388, 2009.
- [17] Joshua E Cates, Aaron E Lefohn, and Ross T Whitaker. Gist : an interactive, gpu-based level set segmentation tool for 3d medical images. *Medical Image Analysis*, 8(3) :217–231, 2004.
- [18] Bala G Chandran and Dorit S Hochbaum. A computational study of the pseudoflow and push-relabel algorithms for the maximum flow problem. *Operations research*, 57(2) :358–376, 2009.
- [19] Shuai Che, Michael Boyer, Jiayuan Meng, David Tarjan, Jeremy W Sheaffer, and Kevin Skadron. A performance study of general-purpose applications on graphics processors using cuda. *Journal of parallel and distributed computing*, 68(10) :1370–1380, 2008.
- [20] Wei Chen, M. Beister, Y. Kyriakou, and M. Kachelries. High performance median filtering using commodity graphics hardware. In *Nuclear Science Symposium Conference Record (NSS/MIC), 2009 IEEE*, pages 4142–4147, 24 2009-nov. 1 2009.
- [21] Wen-Hsiung Chen, C. Smith, and S. Fralick. A fast computational algorithm for the discrete cosine transform. *Communications, IEEE Transactions on*, 25(9) :1004–1009, 1977.
- [22] Yizong Cheng. Mean shift, mode seeking, and clustering. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 17(8) :790–799, 1995.
- [23] Boris V Cherkassky and Andrew V Goldberg. On implementing the push—relabel method for the maximum flow problem. *Algorithmica*, 19(4) :390–410, 1997.
- [24] Christophe Chesnaud, Philippe Réfrégier, and Vlady Boulet. Statistical region snake-based segmentation adapted to different physical noise models. *IEEE Trans. Pattern Anal. Mach. Intell.*, 21(11) :1145–1157, 1999.
- [25] Laurent D Cohen, Eric Bardinet, Nicholas Ayache, et al. Surface reconstruction using active contour models. 1993.
- [26] Dorin Comaniciu and Peter Meer. Mean shift analysis and applications. In *Computer Vision, 1999. The Proceedings of the Seventh IEEE International Conference on*, volume 2, pages 1197–1203. IEEE, 1999.
- [27] Dorin Comaniciu and Peter Meer. Mean shift : A robust approach toward feature space analysis. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(5) :603–619, 2002.
- [28] LJ Cutrona. Synthetic aperture radar. *Radar Handbook, second edition*, ed. M. Skolnik, McGraw-Hill, New York, 1990.
- [29] Kostadin Dabov, Alessandro Foi, Vladimir Katkovnik, and Karen Egiazarian. Image denoising with block-matching and 3d filtering. In *IN ELECTRONIC IMAGING'06, PROC. SPIE 6064, NO. 6064A-30*, 2006.
- [30] Kostadin Dabov, Ro Foi, Vladimir Katkovnik, and Karen Egiazarian. Bm3d image denoising with shape-adaptive principal component analysis. In *Proc. Workshop on Signal Processing with Adaptive Sparse Structured Representations (SPARS'09)*, 2009.
- [31] Ingrid Daubechies. *Ten lectures on wavelets*. Society for Industrial and Applied Mathematics, Philadelphia, PA, USA, 1992.

- [32] Nandan Dixit, Renaud Keriven, and Nikos Paragios. Gpu-cuts : Combinatorial optimisation, graphic processing units and adaptive object extraction. 2005.
- [33] Michael Elad and Michal Aharon. Image denoising via sparse and redundant representations over learned dictionaries. *Image Processing, IEEE Transactions on*, 15(12) :3736–3745, 2006.
- [34] Pedro F Felzenszwalb and Daniel P Huttenlocher. Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2) :167–181, 2004.
- [35] Oliver Fluck, Shmuel Aharon, Daniel Cremers, and Mikael Rousson. Gpu histogram computation. In *ACM SIGGRAPH 2006 Research posters*, page 53. ACM, 2006.
- [36] James D Foley, Andries Van Dam, Steven K Feiner, John F Hughes, and Richard L Phillips. *Introduction to computer graphics*, volume 55. Addison-Wesley Reading, 1994.
- [37] Lester Randolph Ford and Delbert R Fulkerson. *A simple algorithm for finding maximal network flows and an application to the Hitchcock problem*. Rand Corporation, 1955.
- [38] Keinosuke Fukunaga and Larry Hostetler. The estimation of the gradient of a density function, with applications in pattern recognition. *Information Theory, IEEE Transactions on*, 21(1) :32–40, 1975.
- [39] Brian Fulkerson and Stefano Soatto. Really quick shift : Image segmentation on a gpu. In *Trends and Topics in Computer Vision*, pages 350–358. Springer, 2012.
- [40] Frédéric Galland, Nicolas Bertaux, and Philippe Réfrégier. Minimum description length synthetic aperture radar image segmentation. *IEEE Transactions on Image Processing*, 12(9) :995–1006, 2003.
- [41] Olivier Germain and Philippe Réfrégier. Statistical active grid for segmentation refinement. *Pattern Recognition Letters*, 22(10) :1125–1132, 2001.
- [42] Bart Goossens, Hiêp Luong, Jan Aelterman, Aleksandra Pižurica, and Wilfried Philips. A gpu-accelerated real-time nlmeans algorithm for denoising color video sequences. In Jacques Blanc-Talon, Don Bone, Wilfried Philips, Dan Popescu, and Paul Scheunders, editors, *Advanced Concepts for Intelligent Vision Systems*, volume 6475 of *Lecture Notes in Computer Science*, pages 46–57. Springer Berlin Heidelberg, 2010.
- [43] Zhiyu He and Falko Kuester. Gpu-based active contour segmentation using gradient vector flow. In George Bebis, Richard Boyle, Bahram Parvin, Darko Koracin, Paolo Remagnino, Ara Nefian, Gopi Meenakshisundaram, Valerio Pascucci, Jiri Zara, Jose Molineros, Holger Theisel, and Tom Malzbender, editors, *Advances in Visual Computing*, volume 4291 of *Lecture Notes in Computer Science*, pages 191–201. Springer Berlin Heidelberg, 2006.
- [44] Glenn E Healey and Raghava Kondepudy. Radiometric ccd camera calibration and noise estimation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 16(3) :267–276, 1994.
- [45] Dorit S Hochbaum and James B Orlin. Simplifications and speedups of the pseudoflow algorithm. *Networks*, 61(1) :40–57, 2013.
- [46] Bai Hong-tao, He Li-li, Ouyang Dan-tong, Li Zhan-shan, and Li He. K-means on commodity gpus with cuda. In *Computer Science and Information Engineering, 2009 WRI World Congress on*, volume 3, pages 651–655, 2009.

- [47] GEORGE Humphrey. The psychology of the gestalt. *Journal of Educational Psychology*, 15(7) :401, 1924.
- [48] Won-Ki Jeong, Johanna Beyer, Markus Hadwiger, Amelio Vazquez, Hanspeter Pfister, and Ross T Whitaker. Scalable and interactive segmentation and visualization of neural processes in em datasets. *Visualization and Computer Graphics, IEEE Transactions on*, 15(6) :1505–1514, 2009.
- [49] M. Kachelriess. Branchless vectorized median filtering. In *Nuclear Science Symposium Conference Record (NSS/MIC), 2009 IEEE*, pages 4099–4105, 24 2009-nov. 1 2009.
- [50] Michael Kass, Andrew P. Witkin, and Demetri Terzopoulos. Snakes : Active contour models. *International Journal of Computer Vision*, 1(4) :321–331, 1988.
- [51] Yakov Keselman and EVANGELIA Micheli-Tzanakou. Extraction and characterization of regions of interest in biomedical images. In *Information Technology Applications in Biomedicine, 1998. ITAB 98. Proceedings. 1998 IEEE International Conference on*, pages 87–90. IEEE, 1998.
- [52] P. Kestener, Y. Moudden, and A. Pedron. Calcul scientifique sur gpu et application en traitement d'images. Seminaire HPC-GPU, CMLA, ENS Cachan, March 2009.
- [53] Pushmeet Kohli and Philip HS Torr. Dynamic graph cuts for efficient inference in markov random fields. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(12) :2079–2088, 2007.
- [54] Aaron E Lefohn, Joshua E Cates, and Ross T Whitaker. Interactive, gpu-based level sets for 3d segmentation. In *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2003*, pages 564–572. Springer, 2003.
- [55] Aaron E Lefohn, Joe M Kniss, Charles D Hansen, and Ross T Whitaker. Interactive deformation and visualization of level set surfaces using graphics hardware. In *Proceedings of the 14th IEEE Visualization 2003 (VIS'03)*, page 11. IEEE Computer Society, 2003.
- [56] Aaron E Lefohn, Joe M Kniss, Charles D Hansen, and Ross T Whitaker. A streaming narrow-band algorithm : interactive computation and visualization of level sets. In *ACM SIGGRAPH 2005 Courses*, page 243. ACM, 2005.
- [57] Peihua Li and Lijuan Xiao. Mean shift parallel tracking on gpu. In *Pattern Recognition and Image Analysis*, pages 120–127. Springer, 2009.
- [58] Tao Li, Alexandre Krupa, and Christophe Collewet. A robust parametric active contour based on fourier descriptors. In *Image Processing (ICIP), 2011 18th IEEE International Conference on*, pages 1037–1040. IEEE, 2011.
- [59] James MacQueen et al. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, page 14. California, USA, 1967.
- [60] Stéphane Mallat. *A Wavelet Tour of Signal Processing, Third Edition : The Sparse Way*. Academic Press, 3rd edition, 2008.
- [61] Massimo Mancuso and Sebastiano Battiato. An introduction to the digital still camera technology. *ST Journal of System Research*, 2(2), 2001.
- [62] David Martin, Charless Fowlkes, Doron Tal, and Jitendra Malik. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In *Computer Vision, 2001. ICCV 2001*.

- Proceedings. Eighth IEEE International Conference on*, volume 2, pages 416–423. IEEE, 2001.
- [63] S.A. Nene, S.K. Nayar, and Murase H. Columbia object image library (coil-100). Technical Report CUCS-006-96, Computer Vision Laboratory, Columbia University, February 1996.
- [64] NVIDIA Corporation. *NVIDIA CUDA C Programming Guide v4.2*, 7 2012.
- [65] Stanley Osher and James A Sethian. Fronts propagating with curvature-dependent speed : algorithms based on hamilton-jacobi formulations. *Journal of computational physics*, 79(1) :12–49, 1988.
- [66] N. Otsu. A threshold selection method from gray-level histograms. *Systems, Man and Cybernetics, IEEE Transactions on*, 9(1) :62–66, 1979.
- [67] Fernanda Palhano Xavier De Fontes, Guillermo Andrade Barroso, Pierrick Coupé, and Pierre Hellier. Real time ultrasound image denoising. *Journal of Real-Time Image Processing*, May 2010.
- [68] Dan Pelleg, Andrew W Moore, et al. X-means : Extending k-means with efficient estimation of the number of clusters. In *ICML*, pages 727–734, 2000.
- [69] S. Perreault and P. Hebert. Median filtering in constant time. *Image Processing, IEEE Transactions on*, 16(9) :2389–2394, sept. 2007.
- [70] T.Q. Pham and L.J. van Vliet. Separable bilateral filtering for fast video preprocessing. In *Multimedia and Expo, 2005. ICME 2005. IEEE International Conference on*, pages 4 pp.–, 2005.
- [71] F. Porikli. Constant time $o(1)$ bilateral filtering. In *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*, pages 1–8, 2008.
- [72] Mike Roberts, Jeff Packer, Mario Costa Sousa, and Joseph Ross Mitchell. A work-efficient gpu algorithm for level set segmentation. In *Proceedings of the Conference on High Performance Graphics, HPG '10*, pages 123–132, Aire-la-Ville, Switzerland, Switzerland, 2010. Eurographics Association.
- [73] Rémi Ronfard. Region-based strategies for active contour models. *International Journal of Computer Vision*, 13(2) :229–251, 1994.
- [74] Martin Rumpf and Robert Strzodka. Level set segmentation in graphics hardware. In *Image Processing, 2001. Proceedings. 2001 International Conference on*, volume 3, pages 1103–1106. IEEE, 2001.
- [75] R.M. Sanchez and P.A. Rodriguez. Bidimensional median filter for parallel computing architectures. In *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*, pages 1549–1552, march 2012.
- [76] James A Sethian. A fast marching level set method for monotonically advancing fronts. *Proceedings of the National Academy of Sciences*, 93(4) :1591–1595, 1996.
- [77] S.A.Arul Shalom, Manoranjan Dash, and Minh Tue. Efficient k-means clustering using accelerated graphics processors. In Il-Yeol Song, Johann Eder, and Tho-Manh Nguyen, editors, *Data Warehousing and Knowledge Discovery*, volume 5182 of *Lecture Notes in Computer Science*, pages 166–175. Springer Berlin Heidelberg, 2008.
- [78] Jianbo Shi and Jitendra Malik. Normalized cuts and image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(8) :888–905, 2000.

- [79] Erik Smistad, AnneC. Elster, and Frank Lindseth. Real-time gradient vector flow on gpus using opengl. *Journal of Real-Time Image Processing*, pages 1–8, 2012.
- [80] J. Stam. Convolution soup. In *GPU Technology Conference*, Aug. 2010.
- [81] T. Stitch. Graph cuts with cuda. In *GPU Technology Conference*, Oct. 2009.
- [82] Gilbert Strang. The discrete cosine transform. *SIAM review*, 41(1) :135–147, 1999.
- [83] RicardoM. Sánchez and PaulaA. Rodríguez. Highly parallelable bidimensional median filter for modern parallel programming models. *Journal of Signal Processing Systems*, 71(3) :221–235, 2013.
- [84] Albert JP Theuwissen. Ccd or cmos image sensors for consumer digital still photography? In *VLSI Technology, Systems, and Applications, 2001. Proceedings of Technical Papers. 2001 International Symposium on*, pages 168–171. IEEE, 2001.
- [85] C. Tomasi and R. Manduchi. Bilateral filtering for gray and color images. In *Computer Vision, 1998. Sixth International Conference on*, pages 839–846, 1998.
- [86] John Wilder Tukey. *Exploratory Data Analysis*. Addison-Wesley, 1977.
- [87] Andrea Vedaldi and Stefano Soatto. Quick shift and kernel methods for mode seeking. In *Computer Vision–ECCV 2008*, pages 705–718. Springer, 2008.
- [88] V. Vineet and P. J. Narayanan. Cuda cuts : Fast graph cuts on the gpu. In *Computer Vision and Pattern Recognition Workshops, 2008. CVPRW '08. IEEE Computer Society Conference on*, pages 1–8, 2008.
- [89] Vibhav Vineet, Pawan Harish, Suryakant Patidar, and P. J. Narayanan. Fast minimum spanning tree for large graphs on the gpu. In *Proceedings of the Conference on High Performance Graphics 2009, HPG '09*, pages 167–171, New York, NY, USA, 2009. ACM.
- [90] Vasily Volkov. Better performance at lower occupancy. *Proceedings of the GPU Technology Conference, GTC*, 10, 2010.
- [91] Song Wang and Jeffrey Mark Siskind. Image segmentation with minimum mean cut. In *Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on*, volume 1, pages 517–524. IEEE, 2001.
- [92] Song Wang and Jeffrey Mark Siskind. Image segmentation with ratio cut. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(6) :675–690, 2003.
- [93] Zhou Wang, Alan Conrad Bovik, Hamid Rahim Sheikh, Student Member, Eero P. Simoncelli, and Senior Member. Image quality assessment : From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13 :600–612, 2004.
- [94] Henry Wong, M-M Papadopoulou, Maryam Sadooghi-Alvandi, and Andreas Moshovos. Demystifying gpu microarchitecture through microbenchmarking. In *Performance Analysis of Systems & Software (ISPASS), 2010 IEEE International Symposium on*, pages 235–246. IEEE, 2010.
- [95] Zhenyu Wu and Richard Leahy. An optimal graph theoretic approach to data clustering : Theory and its application to image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 15(11) :1101–1113, 1993.
- [96] Chunxia Xiao and Meng Liu. Efficient mean-shift clustering using gaussian kd-tree. In *Computer Graphics Forum*, volume 29, pages 2065–2073. Wiley Online Library, 2010.

- [97] Qingxiong Yang, Kar-Han Tan, and N. Ahuja. Real-time $o(1)$ bilateral filtering. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 557–564, 2009.
- [98] C. T. Zahn. Graph-theoretical methods for detecting and describing gestalt clusters. *IEEE Trans. Comput.*, 20(1) :68–86, January 1971.
- [99] Z. Zheng, W. Xu, and K. Mueller. Performance tuning for cuda-accelerated neighborhood denoising filters. *Workshop on High Performance Image Reconstruction (HPIR)*, pages 52–55, 2011.
- [100] Zuoyong Zheng and Ruixia Zhang. A fast gvf snake algorithm on the gpu. *image*, 2 :4, 2012.

TABLE DES FIGURES

2.1	Comparaison des structures d'un cœur de GPU et d'un cœur de CPU (d'après [64]).	11
2.2	Comparaison des performances des GPUs Nvidia et des CPU Intel (d'après [64]).	12
2.3	Organisation des GPU d'architecture Fermi, comme le C2070 (d'après www.hpcresearch.nl).	13
2.4	Représentation d'une grille de calcul en 2D et des blocs de threads, à 2 dimensions, qui la composent.	14
3.1	Images 256×256 en niveau de gris 8 bits utilisées pour l'illustration des propriétés des filtres. a) l'image de référence non bruitée. b) l'image corrompue par un bruit gaussien d'écart type $\sigma = 25$. c) l'image corrompue par un bruit impulsionnel à 25%.	20
3.2	Filtrage par convolution.	21
3.3	Réduction du bruit impulsionnel par filtre médian.	22
3.4	Réduction de bruit gaussien par filtrage bilatéral de voisinage 5×5. σ_S et σ_I sont les écarts type des fonctions gaussiennes de pondération spatiale et d'intensité.	23
3.5	Filtrage par décomposition en ondelettes et seuillage dur des coefficients inférieurs au seuil T	24
3.6	Filtrage par NL-means pour différentes combinaisons des paramètres de similarité f et de non localité t	25
3.7	Filtrage par BM3D, PSNR=29.3 dB MSSIM=0.41	25
3.8	Performances relatives des filtres médians implémentés sur GPU dans libJacket/ArrayFire, PCMF et BVM et exécutés sur deux modèle de générations différentes.	27
3.9	Illustration pré-chargement en mémoire partagée mise en œuvre dans [99] pour l'implémentation, entre autres, du filtre bilatéral. a) en vert le bloc de threads associé aux pixels centraux. b-e) les blocs de pixels successivement pré-chargés en mémoire partagée. f) la configuration finale de la ROI en mémoire partagée.	28
3.10	Segmentation d'une image en niveaux de gris de 128 × 128 pixels par analyse simple d'histogramme. Colonne de gauche : image d'entrée. Colonne centrale : histogramme des niveaux de gris. Colonne de droite : résultat de la segmentation.	31

3.11	Segmentation d'une image en niveaux de gris de 128×128 pixels par simplification de graphe de type <i>Normalized cut</i> pour un nombre s de segments variant de 2 à 5.	33
3.12	Segmentation d'une image en niveaux de gris de 128×128 pixels par algorithme <i>k-means</i> pour un nombre s de segments variant de 2 à 5. Chaque couleur est associée à un segment. Les couleurs sont choisies pour une meilleure visualisation des différents segments.	34
3.13	Segmentation d'une image en niveaux de gris de 128×128 pixels par algorithme <i>mean-shift</i> pour un rayon de voisinage r de 100, 50, 35 et 25 pixels permettant d'obtenir un nombre s de segments variant respectivement de 2 à 5. Le volume minimal admis pour un segment est fixé à 100 pixels. Chaque couleur est associée à un segment. Les couleurs sont choisies pour une meilleure visualisation des différents segments.	35
3.14	Segmentation d'une image en niveaux de gris de 128×128 pixels par algorithme dit du <i>snake</i> , dans sa version originale. Les paramètres d'élasticité, de raideur et d'attraction ont été fixés respectivement aux valeurs 5, 0.1 et 5.	36
3.15	Évolution du nombre de pixels actifs pour les itération successives de l'implémentation de l'algorithme push-relabel de [81]. Les petites images montrent la localisation des pixels actifs après chaque itération, en blanc.	39
3.16	Segmentation d'une image couleur de 512×512 pixels par l'implémentation GPU quick-shift de [39].	41
3.17	Segmentation d'une image couleur de 2256×3008 pixels.	41
3.18	Segmentation d'images issues d'examens IRM par la méthode des level set à bande étroite.	43
3.19	Segmentation d'une image d'épaule en 1024^2 pixels issue d'un examen IRM par l'implémentation du snake GVF de [43]. Le contour est représenté en rouge et le contour final est obtenu en 11 s.	43
3.20	Extraction de contour par la version GPU de l'algorithme gPb. Les images sont issues de la base BSDS [62].	44
4.1	À gauche : détermination des vecteurs f_{in} et f_{out} . À droite : code de Freeman d'un vecteur en fonction de sa direction, l'origine étant supposée au pixel central, en noir.	49
4.2	Évolution du contour lors de la segmentation d'une image de 512^2 pixels. La convergence est obtenue à l'itération 14 après 44 ms pour un total de 256 nœuds.	52
4.3	Influence du contour initial sur la segmentation. Le contour final 1 est celui de la figure 4.2.	52
4.4	Segmentation de l'image de test en 4000^2 pixels.	53
4.5	Segmentation de l'image de test en 4000^2 pixels avec une cible de petite taille. Le contour initial est celui utilisé à la figure 4.4.	53

4.6	Évolution du coût relatif des trois fonctions les plus consommatrices en temps de calcul en fonction de la taille de l'image à traiter.	54
4.7	Calcul des images cumulées S_x et S_x^2 en trois étapes successives. a) cumul partiel bloc par bloc et mémorisation de la somme de chaque bloc. b) cumul sur le vecteur des sommes partielles. c) ajout des sommes partielles à chaque élément des blocs cumulés.	56
4.8	Structuration des données en mémoire du GPU pour l'évaluation en parallèle de l'ensemble des évolutions possibles du contour.	57
4.9	Comparaison des cycles de déplacement des nœuds. Ligne du haut : version séquentielle. Ligne du bas : version parallèle. Les segments en rouge sont des segments du contour non évalués, alors que ceux en pointillés sont les paires ayant reçu les meilleures évaluations parmi les 8 déplacements possibles des nœuds correspondant.	58
4.10	Détermination des coefficients $C(i, j)$ des pixels du contour.	60
4.11	Segmentations de grandes images, avec le contour initial transposé de celui de la figure 4.2. a) image de 100 MP. b) image de 150 MP.	61
4.12	Détermination intelligente du contour initial en deux phases successives. a) La première étape repose sur un échantillonnage horizontal. b) La seconde étape repose sur un échantillonnage vertical.	62

LISTE DES TABLES

2.1	Caractéristiques des différents types de mémoire disponibles sur le GPU. Pour les mémoires cachées, les latences sont données selon l'accès <i>sans-cache/L1/L2/</i> . Les mesures ont été obtenues à l'aide des microprogrammes de test de [94].	13
4.1	Valeur du coefficient $C(i, j)$ en fonction des valeurs des codes de Freeman des vecteurs f_{in} et f_{out}	50
4.2	Performances (en secondes) de la segmentation par snake polygonal sur CPU en fonction de la taille de l'image à traiter. Le temps sont obtenus avec la même image de test dilatée et bruitée et un contour initial carré dont la distance aux bords est proportionnelle à la taille de l'image. Seule l'image en 15 MP a pu être traitée par une implémentation utilisant SSE2. .	65
4.3	Accélération constatée, pour le calcul des images cumulées, de l'implémentation GPU par rapport à l'implémentation CPU de référence. . .	65
4.4	Comparaison des temps d'exécution de l'implémentation GPU par rapport à l'implémentation CPU de référence, appliqués à une même image dilatée pour en adapter la taille.	65

Résumé :

Ceci est le résumé en français

Mots-clés : Mot-clé 1, Mot-clé 2

Abstract:

This is the abstract in English

Keywords: Keyword 1, Keyword 2

The logo for SPIM (École doctorale SPIM) features a solid yellow horizontal bar on the left, followed by the letters 'S', 'P', 'I', and 'M' in a white, sans-serif font. The 'S' is slightly larger and more stylized than the other letters.

■ École doctorale SPIM 16 route de Gray F - 25030 Besançon cedex
■ tél. +33 (0)3 81 66 66 02 ■ ed-spim@univ-fcomte.fr ■ www.ed-spim.univ-fcomte.fr

The logo for the University of Franche-Comté (UFC) consists of a vertical yellow bar on the left with the text 'UNIVERSITÉ DE FRANCHE-COMTÉ' written vertically inside it. To the right of this bar, the letters 'U' and 'FC' are prominently displayed in a large, bold, black font. Below 'U' and 'FC', the words 'UNIVERSITÉ' and 'DE FRANCHE-COMTÉ' are written in a smaller, black, sans-serif font, stacked on two lines.