

THÈSE

PRÉSENTÉE A

L'UNIVERSITÉ DE BORDEAUX I

ÉCOLE DOCTORALE DES SCIENCES PHYSIQUES

ET DE L'INGÉNIEUR

Par Franck MICHELET

POUR OBTENIR LE GRADE DE

DOCTEUR

SPÉCIALITÉ : AUTOMATIQUE, PRODUCTIQUE, SIGNAL ET IMAGE

**CONTRIBUTION A L'ESTIMATION D'ORIENTATIONS
LOCALES MULTIPLES DANS LES IMAGES NUMERIQUES**

Soutenue le 06 mars 2006

Après avis de :

Mme. Laure BLANC-FERAUD	Directrice de recherche CNRS - INRIA	Rapporteurs
M. Jean Pierre GUEDON	Professeur à l'EPUN, Nantes	

Devant la commission d'examen formée de :

M. Mohamed NAJIM	Professeur à l'ENSEIRB, Bordeaux	Président
M. Christian GERMAIN	Maître de conférences à l'ENITA, Bordeaux	Rapporteur
M. Pierre BAYLOU	Professeur à l'ENSEIRB, Bordeaux	
Mme. Laure BLANC-FERAUD	Directrice de recherche CNRS - INRIA	
Mme. Samia BOUKIR	Professeur à l'EGID, Bordeaux	
M. Jean Pierre GUEDON	Professeur à l'EPUN, Nantes	

A Lauriane

REMERCIEMENTS

Les travaux présentés dans ce mémoire sont l'aboutissement des recherches que j'ai menées ces trois dernières années dans l'équipe Signal et Image du Laboratoire d'Automatique, Productique et Signal de l'Université Bordeaux I.

Tout d'abord, je tiens à remercier Monsieur Oustaloup, Professeur à l'ENSEIRB, pour m'avoir accueilli au sein de son laboratoire, et Monsieur Najim, Professeur à l'ENSEIRB, pour m'avoir intégré dans son équipe et m'avoir fait l'honneur de présider mon jury.

J'exprime ma plus sincère gratitude à Monsieur Baylou, Professeur à l'ENSEIRB, pour avoir accepté de diriger ma thèse. Il a toujours su me faire profiter de son bon sens et de son expérience.

Mes remerciements vont également à Monsieur Germain, Maître de Conférences à l'ENITA, pour son encadrement et la disponibilité dont il fait preuve tout au long de ces trois ans.

Je suis d'autre part très reconnaissant envers Madame Blanc-Féraud, Directrice de Recherche CNRS à l'INRIA, et envers Monsieur Guédon, Professeur à l'EPUN, pour le temps qu'ils ont accordé à la lecture de ce manuscrit, en tant que rapporteurs de ma thèse.

J'adresse également mes sincères remerciements à l'ensemble des membres du laboratoire. Plus particulièrement, un grand merci à Alex, Christel, David, Eric, Flavius, Franck (l'autre), Ioana, Jean-Pierre, Jesus, Julie, Kleydis, Olivier, Pierre, Régis, Rémy, Romi, Sylvain, Tibi, Valérie, Youssef, William et tous les autres, pour les bons moments que nous avons passés ensemble et pour l'aide précieuse qu'ils ont su si bien prodiguer.

Enfin, rien n'aurait été possible sans le soutien de ma famille et de mes amis. Je remercie donc du fond du cœur mes parents, mes frères et sœurs et leurs enfants, les Blasteurs et surtout Lauriane, qui a su être là quand il le fallait.

Table des matières

Notations	1
Introduction	3
Chapitre 1 Orientation et estimation des orientations locales	5
1.1 Introduction	5
1.2 Orientation dans les images en niveaux de gris.....	5
1.2.1 Approche perceptuelle.....	5
1.2.1.1 Orientation unique et constante sur toute l'image	6
1.2.1.2 Existence de l'orientation	7
1.2.1.3 Orientation et confiance.....	8
1.2.1.4 Orientation variable sur l'image	8
1.2.1.5 Orientation et échelle d'observation	9
1.2.1.6 Relation entre l'orientation locale et l'orientation globale	10
1.2.1.7 Orientations multiples.....	12
1.2.1.8 Orientation, direction et sens	12
1.2.1.9 Bilan de l'approche perceptuelle	14
1.2.2 Formalisation.....	14
1.2.2.1 Dimensionnalité intrinsèque	14
1.2.2.2 Formalisation de l'orientation.....	15
1.2.2.3 Modèles locaux pour les images orientées.....	17
1.2.2.4 Limitations des modèles	21
1.2.3 Représentation de l'orientation	22
1.2.3.1 Propriétés requises.....	22
1.2.3.2 Représentation vectorielle	23
1.2.3.3 Représentation tensorielle.....	23
1.2.4 Visualisation de l'orientation	24
1.2.4.1 Objectifs de la visualisation	24
1.2.4.2 Visualisation par superposition d'indicateurs d'orientation	24
1.2.4.3 Cartes d'orientation et de confiance	25
1.2.4.4 Visualisation des orientations multiples	27
1.3 Estimation des orientations locales.....	28
1.3.1 Méthodes dérivatives.....	28
1.3.1.1 Principe.....	28
1.3.1.2 Estimation de la dérivée première	29
1.3.1.3 Gradients optimaux de Canny et de Deriche	30
1.3.1.4 Opérateurs GOP et VOP	30
1.3.1.5 Bilan des approches dérivatives.....	33
1.3.2 Approches utilisant des filtres orientés	33
1.3.2.1 Filtres en quadrature	34
1.3.2.2 Filtres de Gabor	35
1.3.2.3 Filtres Steerable	38
1.3.2.4 Approximation des filtres steerable	40
1.3.2.5 Filtres Wedge Steerable.....	41
1.3.2.6 Filtres angulaires gaussiens	43
1.3.2.7 Réseau Orienté de Lignes	44
1.3.2.8 Bilan des approches filtres orientés	46
1.4 Conclusion.....	46

Chapitre 2 Estimation des orientations locales par un réseau orienté.	49
2.1 Introduction	49
2.2 Principe de l'opérateur	50
2.3 Construction du réseau	51
2.3.1 Géométrie du réseau	51
2.3.1.1 Support rectangulaire du réseau	51
2.3.1.2 Réseau orienté	52
2.3.2 Attribut d'homogénéité calculé le long du réseau	53
2.3.2.1 Attribut calculé le long des lignes	53
2.3.2.2 Homogénéité calculée sur le réseau	55
2.3.2.3 Calcul théorique de la réponse angulaire sur un profil sinusoïdal	55
2.3.3 Confiance de l'estimation	60
2.3.4 Paramètres du réseau	61
2.3.4.1 Echelle et forme du réseau	61
2.3.4.2 Relations entre les paramètres géométriques du réseau	62
2.3.4.3 Echantillonnage des orientations	63
2.3.4.4 Choix des paramètres	63
2.4 Implantation du réseau	64
2.4.1 Détermination des niveaux de gris le long des lignes	64
2.4.1.1 Interpolation 2-D	64
2.4.1.2 Méthodes d'interpolation	65
2.4.2 Implantation rapide du réseau	67
2.4.2.1 Stratégies d'implantation rapide	67
2.4.2.2 Utilisation de rotations de l'image	68
2.4.2.3 Rotation inverse des résultats	68
2.4.2.4 Rotation rapide en trois passes	69
2.4.2.5 Calcul rapide de l'attribut	70
2.4.2.6 Coût calculatoire	71
2.4.2.7 Bilan sur l'implantation, opérateur IRON	72
2.5 Influence des paramètres sur les performances de l'opérateur IRON	73
2.5.1 Estimation d'une seule orientation	73
2.5.1.1 Evaluation de l'influence des paramètres	73
2.5.1.2 Influence de la symétrie	73
2.5.1.3 Influence de l'échantillonnage de la réponse angulaire	74
2.5.1.4 Influence de l'échelle d'analyse	76
2.5.1.5 Influence de la forme du réseau	80
2.5.2 Estimation d'orientations multiples	81
2.6 Comparaison avec d'autres méthodes d'estimation des orientations	85
2.6.1 Comparaison des paramètres	85
2.6.2 Biais d'estimation sur une texture idéale non bruitée	85
2.6.3 Estimation locale de l'orientation	88
2.6.4 Immunité au bruit	90
2.6.5 Robustesse au choix des paramètres	91
2.6.6 Sélectivité angulaire des opérateurs symétriques	93
2.6.7 Sélectivité angulaire des opérateurs asymétriques	98
2.6.8 Coûts calculatoires	101
2.7 Conclusion	103
Chapitre 3 Adaptation de l'opérateur IRON à l'image	105
3.1 Introduction	105
3.2 Bruit non gaussien	106
3.2.1 Problématique	106

3.2.2	Solution envisagée.....	107
3.2.3	Résultats	107
3.3	Image modulée en amplitude	111
3.3.1	Problématique.....	111
3.3.2	Solution envisagée.....	112
3.3.3	Résolution.....	113
3.3.4	Résultats	115
3.3.4.1	Modulation d'amplitude affine	115
3.3.4.2	Modulation d'amplitude affine dans une direction quelconque.....	117
3.3.4.3	Modulation d'amplitude non affine	119
3.3.4.4	Coût calculatoire.....	121
3.4	Adaptation de l'échelle d'analyse	121
3.4.1	Problématique.....	121
3.4.2	Etude de la réponse angulaire.....	122
3.4.3	Solution envisagée.....	123
3.4.4	Résultats	124
3.4.4.1	Estimation globale de l'échelle optimale	124
3.4.4.2	Construction d'un estimateur adaptatif.....	126
3.5	Conclusion.....	131
Chapitre 4	Applications	133
4.1	Introduction	133
4.2	Caractérisation de matériaux composites carbonés	133
4.2.1	Problématique.....	133
4.2.1.1	Contexte.....	133
4.2.1.2	Objectifs	134
4.2.2	Solution envisagée.....	134
4.2.2.1	Principe.....	134
4.2.2.2	Cartes d'orientation	134
4.2.2.3	Suivi des strates par intégration de la pente.....	136
4.2.3	Résultats	137
4.2.4	Conclusion.....	142
4.3	Caractérisation de composés métalliques	142
4.3.1	Contexte	142
4.3.2	Solution envisagée.....	143
4.3.3	Résultats	143
4.3.4	Conclusion.....	145
4.4	Segmentation en télédétection viticole.....	145
4.4.1	Problématique.....	145
4.4.1.1	Enjeux de la segmentation de parcelles	145
4.4.1.2	Acquisition d'images.....	146
4.4.1.3	Méthodes existantes.....	146
4.4.2	Principe.....	147
4.4.3	Mise en oeuvre	147
4.4.3.1	Orientation de la parcelle et rotation.....	147
4.4.3.2	Cartes d'homogénéité et attribut discriminant.....	148
4.4.3.3	Seuillage de l'attribut discriminant.....	151
4.4.3.4	Opérations morphologiques.....	152
4.4.3.5	Processus complet de segmentation.....	152
4.4.4	Discussion	154
4.4.4.1	Résultats complémentaires	154
4.4.4.2	Problèmes rencontrés.....	156

4.4.4.3	Temps d'exécution.....	157
4.4.5	Bilan	157
4.5	Conclusion.....	158
	Conclusion.....	159
	Annexes	161
	Annexe A : Changement d'échelle et lissage des orientations	161
	Annexe B : Masques de convolution des opérateurs GOP et VOP	163
	Annexe C : Fonction radiale des filtres wedge steerable.....	164
	Annexe D : Analyse de la réponse angulaire	165
	Annexe E : Erreur d'estimation en fonction de θ	167
	Annexe F : Variationnelle théorique	169
	Annexe G : Calcul récursif de l'attribut	170
	Annexe H : Sélectivité angulaire et réponse angulaire des opérateurs	171
	Annexe I : Utilisation des filtres de Gabor pour le suivi de strates.....	175
	Bibliographie.....	177
	Publications de l'auteur	181

Notations

I	image étudiée
(x,y)	coordonnées horizontale et verticale d'un point de l'image
$D_{I,x} \times D_{I,y}$	dimensions de l'image (largeur×hauteur)
$f(x,y)$	valeur de l'image au point de coordonnées (x,y)
$d(A,B)$	distance entre A et B
$\theta(x,y)$	orientation au point de coordonnées (x,y)
$\hat{\theta}(x,y)$	orientation estimée au point de coordonnées (x,y)
C	confiance de l'estimation
M	taille du masque de convolution
$D_R \times D_L$	dimensions du réseau de lignes (longueur×largeur)
E	échelle d'analyse
F	facteur de forme
$R(\theta)$	réponse angulaire
T_θ	pas d'échantillonnage de la réponse angulaire
$\Delta_\pi(\theta_1, \theta_2)$	écart angulaire modulo π entre les angles θ_1 et θ_2

Introduction

Dans l'activité de perception visuelle, de nombreux chercheurs ont montré que le système psychovisuel humain fonde la compréhension des scènes sur l'observation de primitives telles que des éléments de contours.

L'orientation de ces primitives est un attribut essentiel qui permet de repérer des agencements familiers tels que les agencements verticaux, horizontaux, parallèles, orthogonaux, etc.

Bien que relevant du sens commun, la notion d'orientation résiste à des transpositions méthodologiques. Ainsi, la formalisation d'un opérateur non ambigu d'estimation de l'orientation s'avère délicate.

Ce mémoire s'intéresse à l'analyse des images directionnelles, c'est-à-dire des images présentant un agencement spatial anisotrope. Ce sont par exemple des images de matériaux composites observés au microscope, des images sismiques, des empreintes digitales ou des images de parcelles viticoles observées par télédétection. La notion d'image est ici comprise au sens large : en général il s'agit de la région d'intérêt.

Nous cherchons à extraire les informations caractéristiques de ces images à travers la détermination de l'orientation de leurs agencements spatiaux.

L'orientation d'une image est étroitement liée à l'échelle d'observation. Ainsi, des méthodes existent pour estimer l'orientation sur toute une image à grande échelle, ou plus localement à petite échelle.

En ce qui concerne l'analyse à grande échelle de l'image, des méthodes fondées sur la transformée de Fourier [Gra 78] permettent de déterminer l'orientation à travers la recherche d'un pic d'énergie dans l'espace fréquentiel. L'estimation de l'orientation globale peut également s'effectuer dans le domaine spatio-temporel, par exemple en utilisant la transformée de Hough [Jai 89], fondée sur des projections spatiales.

L'information d'orientation à grande échelle est souvent insuffisante pour caractériser avec précision une image. Parmi les méthodes d'estimation de l'orientation à petite échelle, citons les méthodes dérivatives, qui associent l'orientation aux variations locales de l'image. Par construction, ces méthodes dérivatives sont toutefois incapables de détecter plus d'une orientation en un même point, comme c'est le cas par exemple à l'intersection de deux lignes.

Enfin, une autre approche consiste à étudier la réponse des convolutions de filtres orientés. Dans leur principe, les filtres orientés permettent d'estimer plusieurs orientations en un même point, et ce à une échelle choisie par l'utilisateur.

A partir d'une définition de l'orientation fondée sur des considérations perceptuelles et des modèles mathématiques, nous proposons un opérateur d'estimation des orientations multiples. L'objectif est d'obtenir un opérateur à la fois précis, peu sensible au bruit, capable d'opérer à n'importe quelle échelle en tout point de l'image, et présentant une meilleure sélectivité angulaire que les méthodes classiques d'estimation.

La solution proposée consiste en un réseau orienté le long duquel nous mesurons l'adéquation de l'image avec un modèle de voisinage orienté.

Ce mémoire s'articule en quatre parties.

Dans le premier chapitre, nous présentons les spécificités de l'orientation et nous en déduisons deux définitions de l'orientation locale : la première fondée sur une perception linéique de l'orientation, la deuxième sur une approche surfacique. Nous montrons également les liens avec les autres méthodes existantes, utilisant leurs propres définitions de l'orientation.

En nous fondant sur notre définition de l'orientation, nous présentons dans le deuxième chapitre un nouvel opérateur d'estimation des orientations locales multiples : IRON (Isotropic and Recursive Oriented Network). Nous en proposons une implantation rapide. Nous effectuons ensuite une analyse des performances de cet opérateur et nous les comparons à celles d'autres méthodes d'estimation des orientations locales multiples présentées dans la littérature.

Dans le troisième chapitre, nous mettons en évidence les capacités d'adaptation de notre méthode d'estimation. En l'adaptant à l'image étudiée, nous montrons comment les performances de l'opérateur IRON peuvent être améliorées. Nous présentons également une version adaptative en échelle de l'opérateur IRON.

Enfin, dans le quatrième et dernier chapitre, nous présentons des applications de l'opérateur IRON à l'analyse de matériaux et à l'étude d'images issues de campagnes de télédétection viticole. Plus spécifiquement, nous montrons comment la connaissance précise de la carte d'orientation permet l'extraction d'attributs pertinents, et comment notre opérateur permet l'élaboration d'un attribut textural permettant de segmenter une image complexe.

Chapitre 1

Orientation et estimation des orientations locales

1.1 Introduction

L'estimation de l'orientation est un processus qui peut se rapprocher d'autres opérations fondamentales liées à l'étude des images, telles que l'extraction des contours, l'estimation du mouvement ou même la détection de points caractéristiques.

Nous étudions dans ce chapitre l'orientation et ses particularités en l'abordant avant tout d'un point de vue perceptuel, à travers l'observation d'images orientées.

Nous proposons ensuite une définition formelle de l'orientation. Nous déduisons plusieurs modèles d'images orientées résultant de cette définition.

Nous présentons enfin diverses méthodes parmi les plus classiques et les plus performantes permettant d'estimer l'orientation, ainsi que des outils nécessaires au traitement des informations liées à l'orientation.

1.2 Orientation dans les images en niveaux de gris

Cette étude de l'orientation concerne les images numériques 2-D monochromatiques formées d'un ensemble fini de pixels dont la luminance est codée par un niveau de gris.

En effet, nous nous limiterons aux images monochromatiques car le processus de reconnaissance des orientations dans le cortex humain dépend peu des couleurs mais surtout de la luminance [Gra95].

Ainsi l'étude de l'orientation dans une image couleur peut s'effectuer en général par l'analyse de l'orientation dans l'image de luminance correspondante.

1.2.1 Approche perceptuelle

La notion d'orientation dans une image est très étroitement liée à la perception visuelle.

Cependant le processus de la perception est complexe et l'estimation de l'orientation demande la prise en compte de plusieurs spécificités.

Dans un premier temps, nous allons donc étudier comment l'orientation se caractérise d'un point de vue perceptuel.

1.2.1.1 Orientation unique et constante sur toute l'image

L'orientation en un point d'une image correspond à l'orientation du ou des axes caractérisant au mieux cette image d'un point de vue perceptuel. Observons par exemple une texture synthétique (Fig. 1.1) pour laquelle l'orientation se définit intuitivement et sans ambiguïté. L'orientation correspond à l'angle perçu sur l'image, mesuré par rapport à une référence que nous choisissons arbitrairement comme étant le demi axe horizontal positif.

L'orientation θ est uniformément perçue sur toute cette image à 30° .

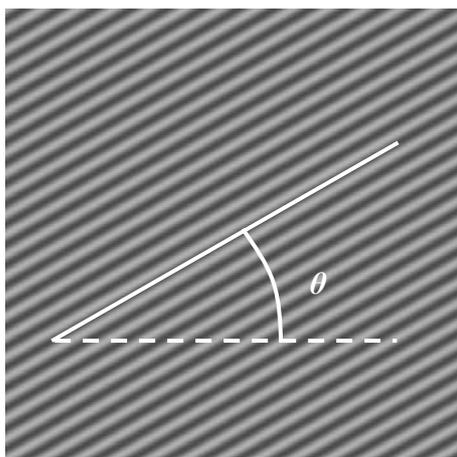


Fig. 1.1 Image présentant une orientation unique de 30°

Notons que dans cet exemple, l'orientation perçue est la même en tout point de l'image.

Nous observons de plus que l'orientation perçue dans cette image correspond à l'orientation des lignes d'iso niveau présentes dans cette image.

Cette dernière observation nous permet de déterminer l'orientation dans certains cas non triviaux : c'est par exemple le cas d'un plan incliné (Fig. 1.2). En cherchant l'orientation qui minimise les variations d'intensité lumineuse sur cette image, nous pouvons déterminer que son orientation est de 20° .

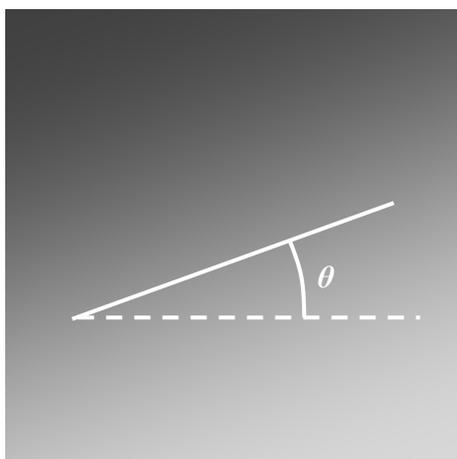


Fig. 1.2 Orientation d'un plan incliné

1.2.1.2 Existence de l'orientation

Cette configuration où l'orientation est définie en tout point de façon unique est assez rare. En effet l'orientation n'existe pas forcément en tout point d'une image. Par exemple, dans une image présentant un niveau de gris uniforme, aucune orientation n'est perceptible et par conséquent la mesure d'orientation est impossible.

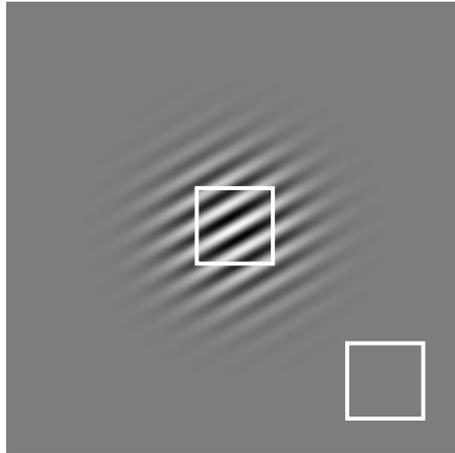


Fig. 1.3 Image ne présentant pas une orientation en tout point

Des configurations moins triviales sont fréquemment rencontrées. Par exemple sur l'image de la figure 1.3, une orientation n'est perceptible qu'au centre de l'image, et pas sur la périphérie.

Dans la suite de ce chapitre nous présenterons les spécificités de l'orientation grâce à des images de synthèse, correspondant généralement à des textures ou des images texturées. La notion de texture est décrite et définie plus en détail dans [Gag 83][Uns 84]. Ces définitions sont rassemblées et comparées dans [Ger 97].

Notons néanmoins que l'orientation peut exister dans des images non texturées. La figure 1.4 présente une image non texturée représentant une gravure ancienne, pour laquelle l'orientation existe en certains points.

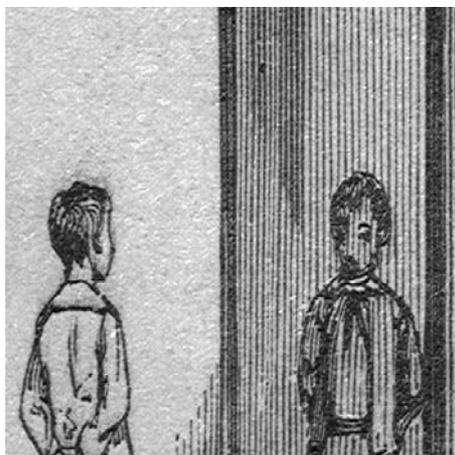


Fig. 1.4 Image orientée non texturée

1.2.1.3 Orientation et confiance

Dans les situations où il est difficile de percevoir l'orientation, comme par exemple pour les images bruitées, un choix binaire désignant la présence ou l'absence d'orientation ne suffit plus.

Il convient alors d'associer une valeur de confiance C à l'orientation. Cette confiance prend généralement des valeurs entre 0 (pas d'orientation) et 1 (présence d'une orientation clairement visible). Les valeurs intermédiaires correspondent aux orientations difficilement perceptibles.

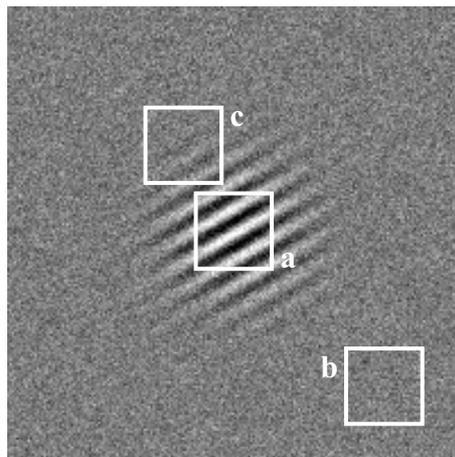


Fig. 1.5 Orientation et confiance

La figure 1.5 présente trois situations pour lesquelles la perception est aisée (zone a), impossible (zone b) et difficile (zone c).

1.2.1.4 Orientation variable sur l'image

Qu'elle existe en tout point ou non et quelle que soit la confiance qui lui est associée, l'orientation n'est pas forcément unique ni constante sur toute l'image.

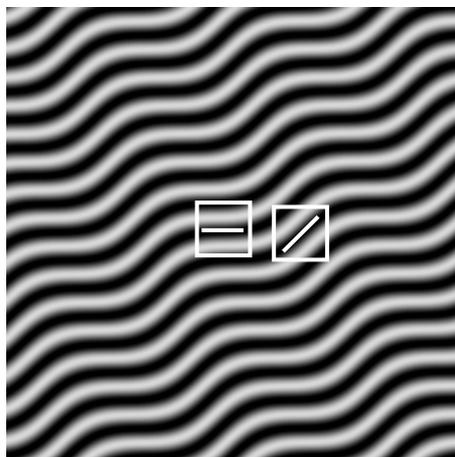


Fig. 1.6 Orientation variable sur l'image

Par exemple, la figure 1.6 présente une image modulée en orientation, pour laquelle l'orientation varie en fonction de la position de la fenêtre d'observation.

Sur cette figure ainsi que sur les suivantes, nous représentons la fenêtre d'observation de l'image par un carré de taille variable. L'orientation observable dans cette fenêtre est matérialisée par un segment de droite blanc.

A travers cet exemple nous constatons que l'orientation dans une image dépend du point d'analyse. Il est par conséquent nécessaire de connaître l'orientation dans une image en chaque point.

Nous chercherons donc à étudier l'orientation de l'image en fonction de la position étudiée. Cette orientation en chaque point de l'image est notée $\theta(x, y)$.

Déterminer $\theta(x, y)$ revient à chercher l'orientation perçue en chaque point de l'image.

En présence de variations de l'orientation, les lignes d'iso niveau ne sont plus des droites ni des segments de droite mais des courbes.

La figure 1.7 présente un détail de la texture précédente. La ligne d'iso niveau passant par le point A est matérialisée par une courbe blanche. L'orientation perçue au point A est d'environ 40° .

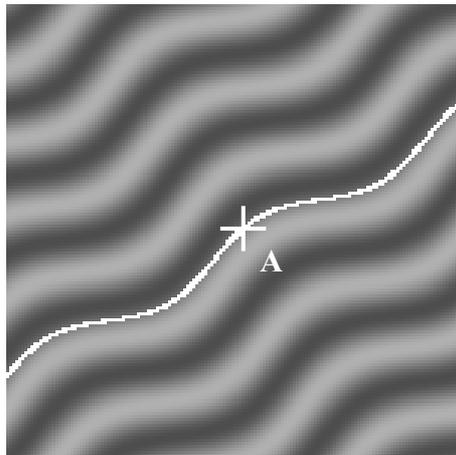


Fig. 1.7 Modulation d'orientation

En outre, il ressort de l'observation de cette image qu'en présence d'une courbure, l'orientation en un point de coordonnées $A(x_A, y_A)$ correspond à l'orientation de la tangente de la ligne d'iso niveau passant par ce point. L'évolution de $\theta(x, y)$ est donc étroitement liée à la notion de courbure, dont la définition est donnée dans [DoC 76] ou [Don 99].

1.2.1.5 Orientation et échelle d'observation

A l'instar de la localisation, la taille de la fenêtre d'observation (également nommée échelle d'analyse) joue un rôle prépondérant dans le processus d'estimation de l'orientation.

La figure 1.8 illustre ce phénomène. A petite échelle nous observons une orientation variant de 0° à 45° suivant la localisation.

A plus grande échelle (ici à l'échelle globale pour l'image) l'orientation de l'image est constante et vaut 20° .

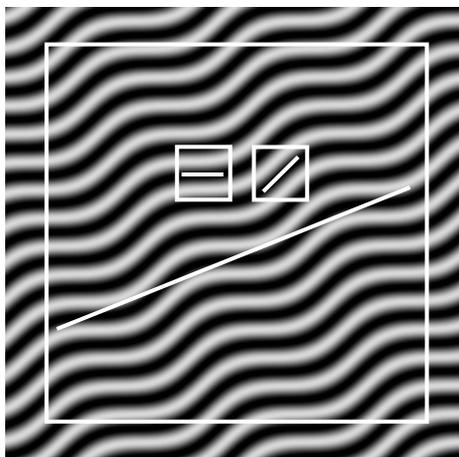


Fig. 1.8 Image présentant des orientations différentes selon l'échelle d'analyse

Par la suite, quand nous ferons référence à une orientation locale, il s'agira d'une orientation estimée en un point, à une échelle aussi petite que possible.

Quand nous parlerons d'orientation globale, il s'agira de l'orientation observée à l'échelle la plus grande possible, c'est-à-dire celle correspondant à la taille de l'image ou de la région d'intérêt. L'orientation globale d'une image correspond à sa tendance directionnelle générale et s'applique à toute l'image.

1.2.1.6 Relation entre l'orientation locale et l'orientation globale

Sur l'image précédente (Fig. 1.8), l'orientation globale de l'image n'est pas identique aux orientations déterminées à plus petite échelle. Néanmoins, les orientations locales ne correspondent ici qu'à des variations autour d'une même tendance directionnelle globale.

Connaissant les orientations locales, il est en général possible d'en déduire la tendance directionnelle globale par des méthodes telles que l'Analyse en Composantes Principales (ACP) [Don 99], le Vecteur Directionnel Moyen (VDM) [Ger 03] ou l'algorithme de Rao [Rao 90]. Ces méthodes sont décrites de manière plus détaillée en Annexe A.

Alors qu'une telle déduction de l'orientation globale est possible sur la figure 1.8, certaines configurations d'orientations locales ne correspondent à aucune orientation globale, et d'autres configurations ne permettent pas d'accéder à la tendance directionnelle globale.

La figure 1.9, composée de cercles concentriques, illustre le premier cas de figure.

Pour cette image, l'orientation globale n'existe pas, mais cette situation limite permet encore l'existence d'une relation entre les orientations locales et l'orientation globale : la moyenne vectorielle des orientations locales par le VDM ou l'ACP (Annexe A) indique un vecteur nul, ce qui correspond bien à l'absence d'orientation globale. La partie 1.2.3 décrira plus précisément la représentation vectorielle de l'orientation.

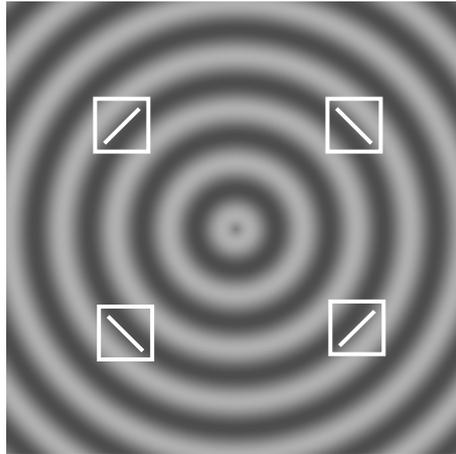


Fig. 1.9 Des orientations locales mais pas de tendance directionnelle globale

Il n'est pas toujours possible de lier l'orientation locale à l'orientation globale. Nous exposons maintenant le cas d'images pour lesquelles l'orientation à petite échelle existe, de même que l'orientation à grande échelle, mais pour lesquelles il n'existe aucune relation entre ces orientations observées à différentes échelles.

L'image de la figure 1.10-a est constituée d'alignements d'objets et ces alignements déterminent une orientation globale perçue à 30° . L'orientation locale correspond quant à elle à l'orientation des contours des objets circulaires, et la moyenne de ces orientations locales correspond au vecteur nul.

L'exemple de la figure 1.10-b illustre le cas d'alignements d'objets orientés. La moyenne des orientations locales indique la direction horizontale alors que l'orientation globale perçue est de 20° .

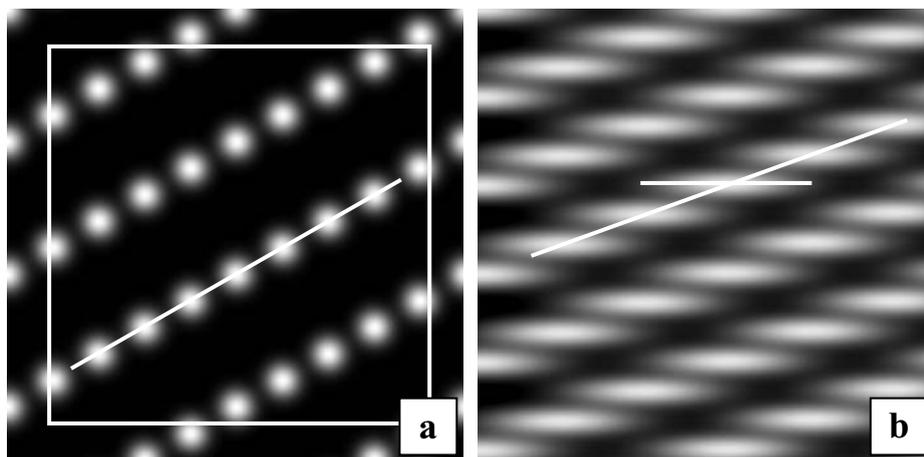


Fig. 1.10 Images orientées constituées d'objets

Dans de telles images constituées d'alignements d'objets distincts, l'orientation peut s'avérer ambiguë. Lors de l'estimation de l'orientation dans une telle image, nous devons donc choisir si nous souhaitons mesurer l'orientation locale des éléments qui la constituent ou l'orientation des motifs constitués par l'agencement de ces éléments, et il sera impossible par la suite d'établir de lien entre ces deux grandeurs.

Afin d'éviter toute ambiguïté, nous limiterons notre étude aux images (ou aux régions d'images) présentant des orientations régulières, c'est-à-dire aux images pour lesquelles les orientations locales ainsi que l'orientation globale existent et la moyenne des orientations locales converge vers l'orientation globale lorsque la fenêtre de moyennage croît.

1.2.1.7 Orientations multiples

A travers l'observation d'images à différentes échelles, nous avons pu observer que plusieurs orientations peuvent être perçues en un même point de l'image.

En fait, les situations où des orientations multiples existent en un même point correspondent à deux cas distincts :

- à une échelle donnée, une seule orientation est perçue au point étudié. A plus grande échelle, une autre orientation apparaît en ce même point.
- plusieurs orientations coexistent au point étudié, quelle que soit l'échelle d'observation.

La figure 1.11-a fait apparaître plusieurs orientations au point *A* mais à des échelles différentes. La figure 1.11-b met en évidence des orientations multiples au point *B*, et ce quelle que soit l'échelle d'observation.

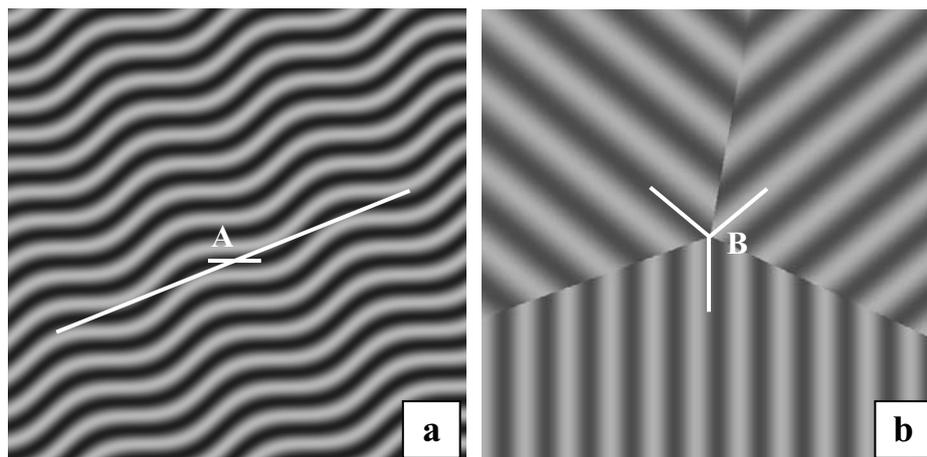


Fig. 1.11 Orientations multiples à diverses échelles (a), ou en un même point (b)

Le premier cas d'orientations multiples en un même point peut se ramener à un choix d'échelle. C'est pourquoi, lorsque nous évoquerons les orientations multiples par la suite, nous nous référerons au cas où plusieurs orientations coexistent en un même point, quelle que soit l'échelle d'analyse.

1.2.1.8 Orientation, direction et sens

Nous devons maintenant préciser une partie du vocabulaire qui sera utilisé par la suite concernant les orientations.

Dans le cas général l'orientation peut être assimilée à une simple direction et par conséquent elle est estimée modulo π . C'est par exemple le cas en tout point de l'image de la figure 1.12-a, et aux points d'intersection des lignes d'iso niveau de la figure 1.12-b.

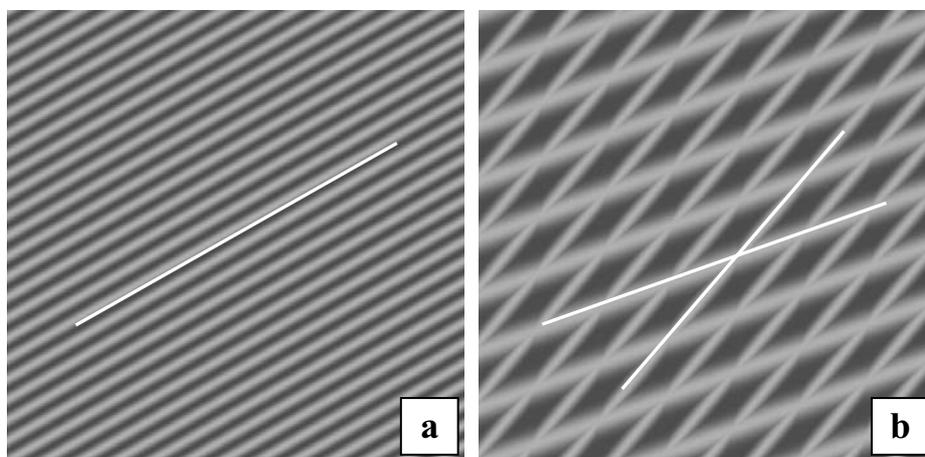


Fig. 1.12 Orientations modulo π

Néanmoins, l'orientation n'est pas toujours perçue modulo π . En particulier, si la configuration locale de l'image est fortement dissymétrique par rapport au point d'observation, nous devons associer un sens à la direction des axes caractéristiques. L'orientation est alors une donnée estimée modulo 2π .

C'est notamment le cas à l'extrémité des lignes d'iso niveau (Fig. 1.13-a) ou lors de variations brutales de l'orientation conduisant à des orientations multiples (Fig. 1.13-b).

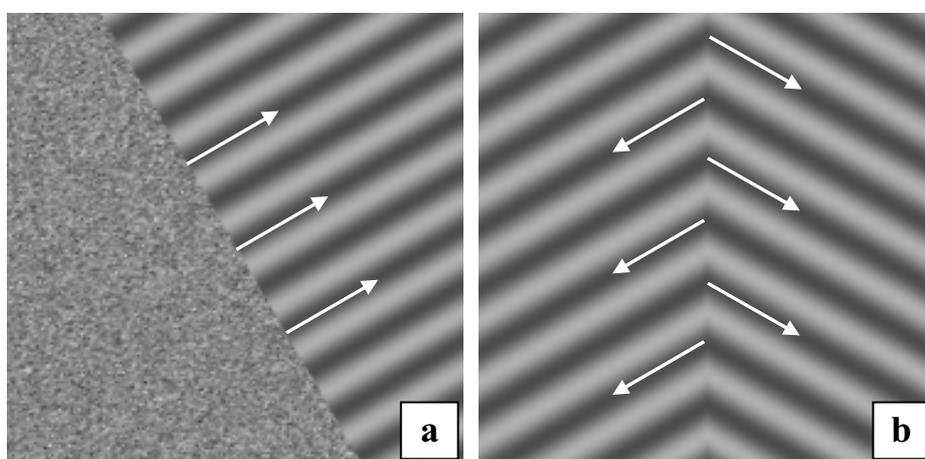


Fig. 1.13 Orientation modulo 2π

Par la suite, quand nous estimerons l'orientation, nous nous référerons donc selon le cas à une donnée estimée modulo π ou modulo 2π .

1.2.1.9 Bilan de l'approche perceptuelle

A travers cette étude perceptuelle, nous avons dégagé les particularités de l'orientation. Tout d'abord l'orientation dans une image correspond à la perception d'un angle. Cet angle est évalué entre une référence arbitraire (en général l'axe horizontal) et la direction perçue dans l'image.

L'orientation n'existe pas en tout point de l'image. Pour que l'orientation existe, il est nécessaire de pouvoir observer des lignes perceptuelles. Nous caractérisons la présence ou l'absence d'orientations par une valeur de confiance allant de 0 pour l'absence d'orientation à 1 pour une orientation clairement perceptible. Les valeurs intermédiaires caractérisent des orientations difficilement perceptibles.

L'orientation n'étant pas forcément constante sur l'image, nous devons l'évaluer en chaque point. L'orientation perçue dépend de l'échelle d'observation. Dans les images présentant une orientation régulière, il y a corrélation entre l'orientation locale (à petite échelle) et l'orientation globale (à grande échelle). Il est alors possible de déterminer l'orientation globale à partir des orientations locales.

A une échelle donnée, il est possible de trouver en un point de l'image une seule orientation ou des orientations multiples.

Enfin les orientations peuvent être définies modulo 2π ou modulo π , selon que le sens des orientations perçues est significatif ou non.

1.2.2 Formalisation

1.2.2.1 Dimensionnalité intrinsèque

Nous allons nous intéresser à la caractérisation locale des images orientées.

Krieger et al. [Kri 96][Bül 01] a défini la dimensionnalité intrinsèque des signaux multidimensionnels.

La dimensionnalité intrinsèque est une caractéristique locale d'un signal multidimensionnel. Elle ne concerne donc qu'un voisinage donné autour d'un point.

Elle est étroitement liée aux degrés de liberté utilisés par un signal multidimensionnel.

Définition 1 : classification locale de l'image

Dans une image I dont les valeurs sont définies par la fonction f , le voisinage $V(A)$ centré sur le point d'intérêt $A(x_A, y_A)$ peut être affecté à une classe de signaux $\{i0D\}$, $\{i1D\}$ ou $\{i2D\}$ (respectivement les signaux de dimensionnalité intrinsèque 0, 1 ou 2) en fonction de la règle suivante :

$$V(A_0) \in \begin{cases} \{i0D\} & \text{si } \forall (x, y) \in V(A_0), f(x, y) = \lambda, \text{ avec } \lambda \in \mathfrak{R} \\ \{i1D\} & \text{si } \exists h \text{ une fonction et } (\alpha, \beta) \in \mathfrak{R}^2 - (0, 0) : f(x, y) = h(\alpha.x + \beta.y) \\ \{i2D\} & \text{sinon} \end{cases}$$

La dimensionnalité intrinsèque décrit la complexité locale de l'image. Elle va fortement influencer sur la perception des orientations locales.

1.2.2.2 Formalisation de l'orientation

De nombreux travaux s'appuient sur le fait que l'orientation locale d'une image correspond à l'orientation des lignes et des contours qui la composent [Can 83][Coc 95][Der 90][Ive 95][Jac 04].

Cependant, à une échelle donnée, il n'y a pas toujours présence de lignes ou de contours. C'est par exemple le cas du plan incliné (Fig. 1.2) : bien que l'orientation existe et soit perceptible, nous ne pouvons alors pas caractériser cette orientation par une définition fondée sur les lignes ou les contours.

Notre définition de l'orientation locale est fondée sur des considérations perceptuelles. Cette définition reposant sur la notion de ligne d'iso niveau, nous en fournissons une définition :

Définition 2 : définition des lignes d'iso niveau

Soit une image I , assimilée à une fonction $f : \Omega \rightarrow \mathfrak{R}$, $\Omega \subset \mathfrak{R}^2$.

Ω est l'union des fermés $\overline{\Omega}_i : \Omega = \bigcup_{i=1}^n \overline{\Omega}_i$ et Ω' est l'union des ouverts $\Omega_i : \Omega' = \bigcup_{i=1}^n \Omega_i$

Nous supposons f continue dans les ouverts Ω_i , et nous supposons également que

$$\forall i \in [1, \dots, n], \forall x \in \Omega_i, \lim_{\substack{t \rightarrow x \\ t \in \Omega_i}} f(t) \text{ existe.}$$

- Soit $x_0 \in \Omega'$, nous notons $\Gamma_{x_0} = \{x \in \Omega' : f(x) = f(x_0)\}$.

L'ensemble Γ_{x_0} hérite sa topologie de Ω , donc de \mathfrak{R}^2 .

La ligne d'iso niveau au point x_0 est γ_{x_0} , la composante connexe de Γ_{x_0} qui contient x_0 .

- Soit $x_0 \in \Omega \setminus \Omega'$, $\exists I_{x_0} = \{i_1, \dots, i_k\} : x_0 \in \overline{\Omega_{i_m}}, m \in [1, \dots, k]$

Soit $m \in [1, \dots, k]$, nous notons alors $\Gamma_{x_0, m} = \left\{ x \in \Omega_{i_m} : f(x) = \lim_{\substack{t \rightarrow x_0 \\ t \in \Omega_{i_m}}} f(t) \right\}$

Soit $\overline{\Gamma_{x_0, m}}$ fermé contenant x_0 et $\gamma_{x_0, m}$ la composante connexe de $\overline{\Gamma_{x_0, m}}$ contenant x_0 .

L'ensemble des lignes d'iso niveau au point x_0 est donc $\gamma_{x_0} = \bigcup_{m=1}^k \gamma_{x_0, m}$

Notons que cette définition des lignes d'iso niveau ne correspond à la définition couramment admise en topographie que pour des points situés en dehors des zones de discontinuité de la fonction f .

Notons également que dans le cas général, γ_{x_0} peut être un point, une ligne ou une surface. Dans le cas des images de dimensionnalité intrinsèque supérieure ou égale à 1, γ_{x_0} est généralement une ligne ou un point. De plus si γ_{x_0} est un point, nous pouvons conclure que l'orientation n'est pas définie au point x_0 .

Il est possible que pour un voisinage de dimensionnalité intrinsèque égal à 1, γ_{x_0} soit une surface. C'est par exemple le cas lorsque le profil h est un créneau.

A titre d'exemple, nous donnons un exemple de lignes de niveau en un point donné (Fig. 1.14). Une seule ligne de niveau passe par le point A (situé à l'intérieur d'une zone homogène), alors que plusieurs lignes de niveau confluent au point B (situé à la limite entre trois frontières). Au point B , le niveau de chaque ligne dépend de la zone étudiée.

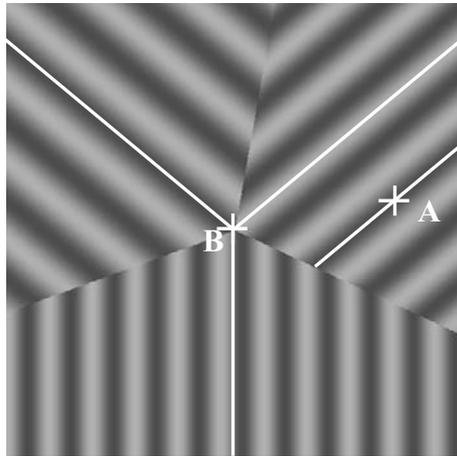


Fig. 1.14 Exemples de lignes de niveau

A partir de cette définition des lignes de niveau, nous pouvons définir l'orientation locale :

Définition 3 : définition linéique de l'orientation

Soit une image I , dont le voisinage $V(A)$ en un point donné $A(x_A, y_A)$ a une dimensionnalité intrinsèque supérieure ou égale à 1.

- Si γ_A est un point, alors il n'y a pas d'orientation au point A .
- Si γ_A est une ligne ou un ensemble de lignes, les orientations locales $\{\theta_i(x_A, y_A)\}$ au point A correspondent aux orientations des tangentes aux lignes d'iso niveau confluant au point A .
- Si γ_A est une surface ou un ensemble de surfaces, alors les orientations locales $\{\theta_i(x_A, y_A)\}$ au point A correspondent aux orientations des tangentes aux contours de ces surfaces.

Pour les points dont le voisinage est de dimensionnalité intrinsèque nulle, l'orientation n'est pas définie : il convient d'associer une confiance nulle à l'orientation en ces points.

A cette définition fondée sur les lignes de niveau correspond une définition surfacique de l'orientation :

Définition 4 : définition surfacique de l'orientation

Soit une image I dont les valeurs sont données par $f(x, y)$. Soit un point $A(x_A, y_A)$ de cette image dont le voisinage a une dimensionnalité intrinsèque supérieure ou égale à 1.

S'il existe une fonction de profil h et un angle $\theta \in [0, 2\pi]$ tels que :

$$\min_{(h, \theta)} d(f(x, y), h(x \cdot \sin(\theta) + y \cdot \cos(\theta)))_{(x, y) \in V(A, \theta)} < \varepsilon,$$

alors on dit que θ est une des orientations au point A .

$V(A, \theta)$ est le voisinage du point A dans la direction θ . Ce voisinage peut être asymétrique par rapport à A ou symétrique (Fig. 1.15-a et Fig. 1.15-b respectivement). L'orientation sera alors définie modulo 2π ou modulo π .

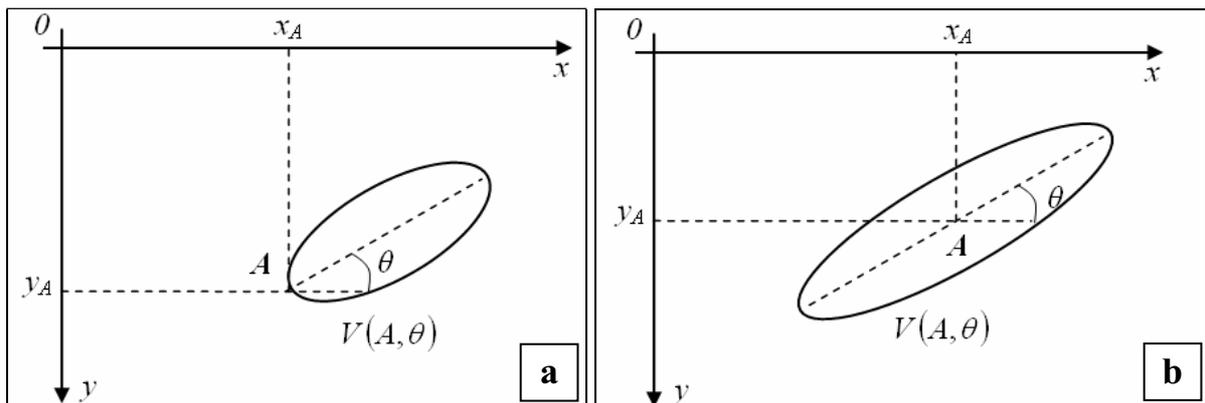


Fig. 1.15 Voisinages $V(A, \theta)$ au point A dans la direction θ

1.2.2.3 Modèles locaux pour les images orientées

La notion de dimensionnalité intrinsèque et sa relation avec notre définition de l'orientation locale nous permettent de définir des modèles locaux pour la luminance des images orientées.

Pas d'orientation locale

Les voisinages de classe $\{i0D\}$ ne présentant aucune orientation, nous choisissons comme modèle d'image non orientée une image présentant un niveau de gris constant.

$$f(x, y) = \lambda, \lambda \in \mathfrak{R} \tag{1.1}$$

Orientation locale unique

Le cas de figure où une seule orientation existe dans un voisinage donné correspond aux voisinages de classe $\{1D\}$. Ceci correspond au cas où le voisinage peut être décrit par une fonction d'une seule variable dans un système de coordonnées correctement orienté. Les constantes α et β (définition 1) correspondent au changement de repère.

Nous prenons donc comme modèle d'image présentant une orientation unique une image dont l'intensité est déterminée par une fonction de profil 1-D h presque partout non nulle :

$$f_{\theta_0}(x, y) = h(t_{\theta_0}) , t_{\theta_0} = x \cdot \sin(\theta_0) + y \cdot \cos(\theta_0) \tag{1.2}$$

Ce modèle a déjà été utilisé dans le cadre de travaux portant sur l'estimation de l'orientation locale, notamment [LeP 03]. L'orientation locale en tout point d'une telle image est θ_0 , et cette orientation correspond à celle indiquée par la définition 3 de l'orientation locale.

La figure 1.15 présente une texture de fonction génératrice $h(t_{\theta_0}) = \cos\left(\frac{2\pi}{T} t_{\theta_0}\right)$ pour laquelle $\theta_0 = \pi/6$.

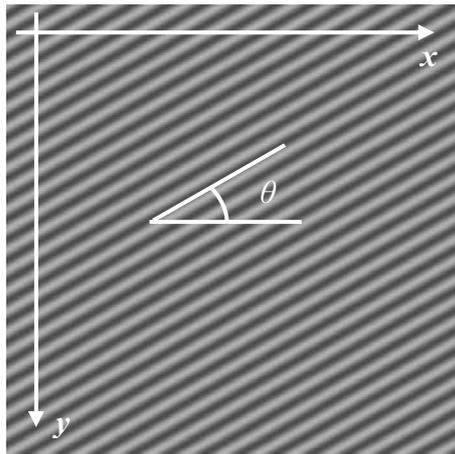


Fig. 1.16 Image présentant une orientation unique

Orientations locales multiples

Un voisinage présentant des orientations locales multiples appartient nécessairement à la classe des images $\{2D\}$.

D'après Krieger et al. [Kri 96], les deux principaux cas que nous devons considérer sont d'une part les changements brutaux d'orientation et d'autre part les occlusions, qu'il définit comme étant les zones où plusieurs contours 1-D se recouvrent les uns les autres.

Les changements brutaux d'orientation et les occlusions sont deux phénomènes distincts. Nous pouvons néanmoins les interpréter tous deux à partir de combinaisons d'images relevant de notre modèle décrivant les voisinages présentant une orientation locale unique. Nous allons déterminer deux modèles différents pour décrire les orientations multiples, chacun de ces modèles correspondant à un type de combinaison différent.

En ce qui concerne les changements brutaux d'orientation, le modèle le plus évident consiste en une juxtaposition de plusieurs textures orientées, chacune de ces textures orientées étant définies à l'aide de notre précédent modèle. La figure 1.17 présente la juxtaposition de deux (Fig. 1.17-a) puis de trois (Fig. 1.17-b) textures orientées.

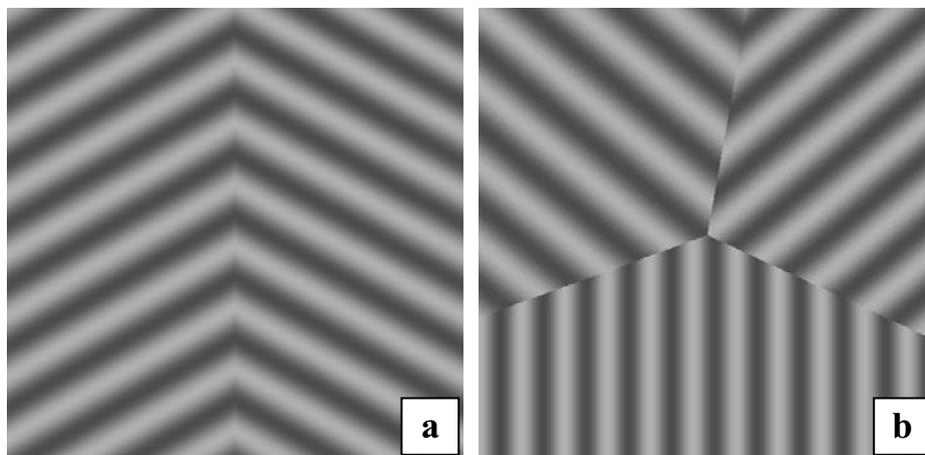


Fig. 1.17 Orientations multiples obtenues par juxtaposition

Notons que ce modèle de juxtaposition couvre le cas particulier de plusieurs zones de niveau de gris homogènes. La figure 1.18 présente une étoile dite de Siemens, dotée de 16 contours.

Au point *A*, pour chacune des 16 zones, la 'ligne' d'iso niveau correspond à une surface. Cette surface est égale à la zone considérée.

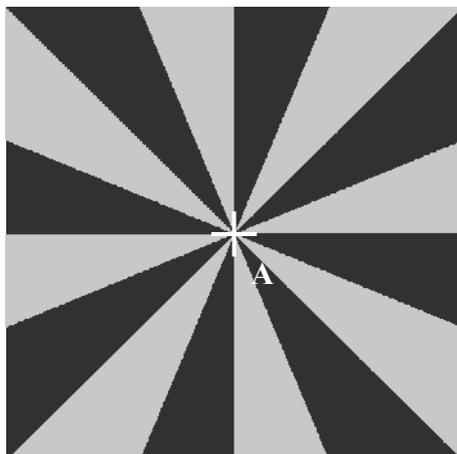


Fig. 1.18 Etoile de Siemens dotée de 16 contours

D'après notre définition linéique de l'orientation (définition 3), l'orientation au point *A* correspond à l'orientation des contours des surfaces d'iso niveau, c'est-à-dire les orientations des contours des branches de l'étoile.

Les occlusions peuvent être modélisées de plusieurs façons. Une combinaison par occlusion doit permettre de percevoir les différentes orientations existantes simultanément en un même point. La méthode d'occlusion que nous avons retenue ici est la combinaison par extremum. L'image obtenue (Fig. 1.19-c) résulte du calcul du maximum de deux images présentant des orientations simples (Fig. 1.19-a et Fig. 1.19-b).

Sur une telle image, les orientations locales correspondent bien aux orientations des tangentes aux lignes d'iso niveau de l'image, ce qui est en accord avec la définition linéique de l'orientation (définition 3).

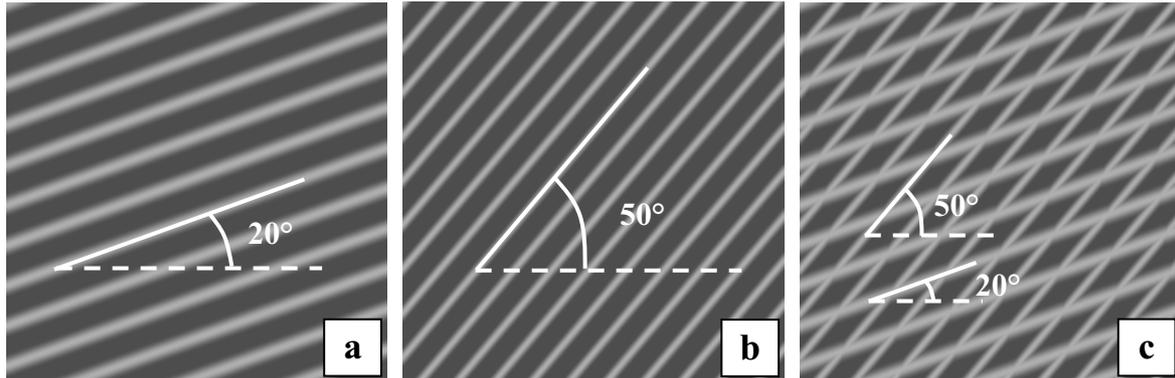


Fig. 1.19 Combinaison de deux images : orientations multiples par occlusion

Les images présentant des orientations multiples sont parfois décrites comme la somme (ou la moyenne) de plusieurs images présentant des orientations simples.

Nous ne retiendrons pas cette méthode de combinaison car les orientations perceptuelles résultant d'un tel mélange additif sont rarement les orientations des images constituant le mélange.

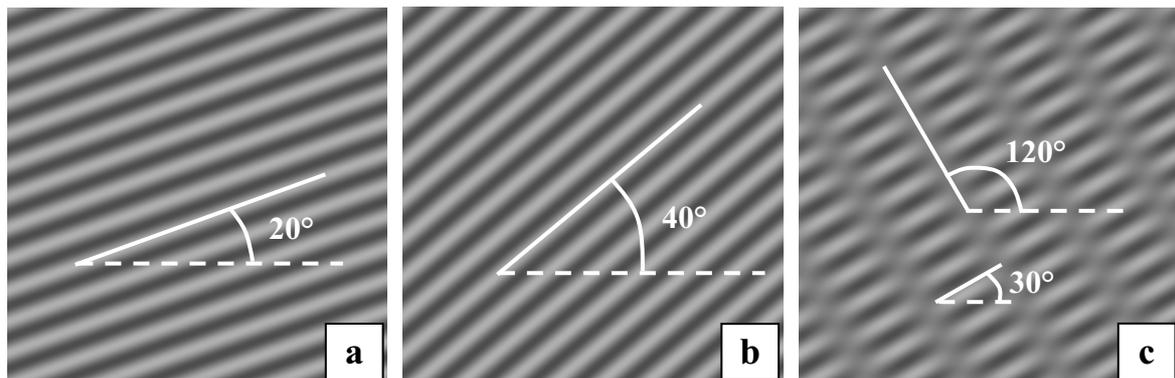


Fig. 1.20 Mélange additif d'images orientées : non conservation des orientations.

Pour s'en convaincre, nous présentons deux textures de profils sinusoïdaux d'orientations respectives 20° et 40° (Fig. 1.20-a et Fig. 1.20-b) ainsi que l'image résultant de la moyenne de ces deux textures (Fig. 1.20-c). Les orientations perceptuelles présentes dans cette image sont 30° et 120°.

Ces orientations perceptuelles, en accord avec la définition 3, correspondent aux tangentes aux lignes d'iso niveau.

Le mélange additif n'étant pas conservatif pour l'orientation, il n'est donc pas retenu dans le cadre de notre modélisation.

1.2.2.4 Limitations des modèles

Comme tout modèle, ceux que nous présentons constituent une simplification de la réalité.

Il convient donc d'étudier les limites de notre définition et des trois modèles que nous en avons déduit, en particulier du point de vue de l'estimation des orientations locales.

La plupart des images correspondent à la représentation 2-D de scènes 3-D naturelles. Il est par conséquent fréquent d'observer des variations lentes de luminance sur les images, correspondant à des variations d'éclairage de la scène représentée. La figure 1.21 présente une texture de profil sinusoïdal modulée en amplitude.

Alors que l'orientation sur cette image est uniforme, nous observons que les lignes d'iso niveau (dont les tangentes sont représentées par des segments de droite blancs) varient en orientation en fonction du point considéré.

L'orientation locale est donc biaisée par cette modulation.

Dans le cas où l'estimation de l'orientation se fait à une échelle supérieure à la période du motif, ces variations d'orientation peuvent se compenser mutuellement.

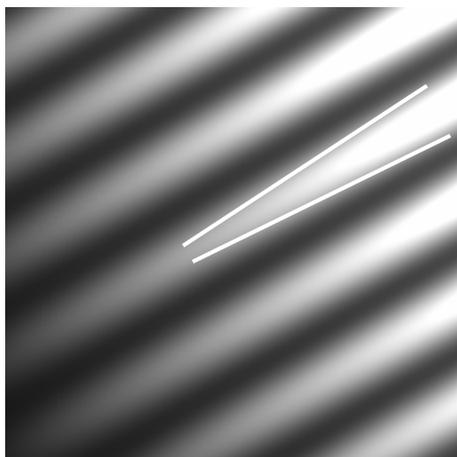


Fig. 1.21 Profil sinusoïdal modulé en amplitude

Les modèles que nous avons proposés correspondent à des images idéales, qui ne sont pas entachées de bruit. La figure 1.22 montre l'influence d'un bruit blanc gaussien additif sur les lignes d'iso niveau.

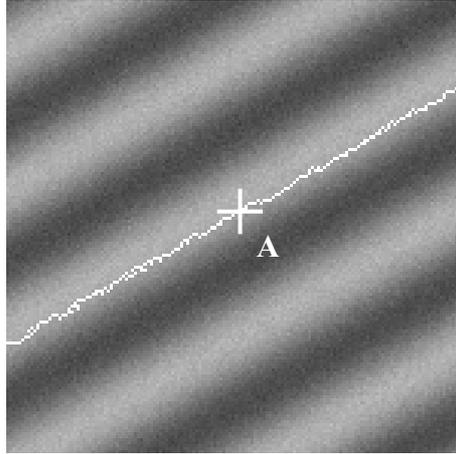


Fig. 1.22 Bruit blanc gaussien additif

La ligne d'iso niveau passant par le point A est symbolisée en blanc. On remarque que cette ligne est perturbée la présence du bruit blanc additif. L'orientation globale de la ligne reste cependant inchangée.

Lors de l'estimation de l'orientation, nous devons donc nous efforcer de chercher les directions qui approximent au mieux les lignes d'iso niveau passant par un point donné.

Nous rechercherons donc les orientations le long desquelles le niveau de gris sera le plus homogène.

1.2.3 Représentation de l'orientation

1.2.3.1 Propriétés requises

Afin de pouvoir interpréter correctement l'orientation d'une image et de pouvoir mener des calculs sur l'orientation, il est nécessaire de choisir un moyen approprié de représenter l'orientation.

L'utilisation seule de l'angle θ ne permet pas de prendre en compte toutes les particularités de l'orientation, en particulier son éventuelle non-existence. Nous devons lui associer la valeur de confiance C .

La manipulation du couple (θ, C) est peu pratique et son utilisation ne permet pas d'effectuer certains calculs directement, l'orientation étant une donnée périodique (circulaire ou demi-circulaire). C'est par exemple le cas pour un calcul de moyenne d'angles.

Le choix d'une représentation de l'orientation appropriée n'est donc pas trivial.

Knutsson [Knu 89] et Granlund et al. [Gra 95] ont défini trois critères que doit satisfaire une représentation de l'orientation.

- Le premier critère est l'unicité de la représentation. Une orientation ne doit être représentée que par une seule et unique entité.

- Le deuxième critère est l'invariance. Pour notre modèle local textural présentant une orientation unique (Eq. 1.2), ce critère correspond au fait que la représentation de l'orientation ne doit pas dépendre de la fonction génératrice h du modèle.

- Le troisième critère est l'équivariance entre l'orientation et sa représentation. La représentation de l'orientation doit conserver la métrique de l'espace des orientations : à une variation d'orientation donnée doit correspondre à une variation proportionnelle de sa

représentation. Ceci est nécessaire si on souhaite pouvoir calculer des différences ou des moyennes angulaires.

1.2.3.2 Représentation vectorielle

Une manière très intuitive de représenter l'orientation consiste à associer à chaque orientation, en chaque point de l'image, un vecteur correspondant à cette orientation.

Ces vecteurs sont définis par :

$$\vec{V}(x, y) = \begin{pmatrix} C \cdot \cos(\theta(x, y)) \\ C \cdot \sin(\theta(x, y)) \end{pmatrix} \quad (1.3)$$

Le scalaire C est la norme du vecteur d'orientation. Dans le cadre de l'estimation de l'orientation nous pourrions souhaiter que cette norme représente la confiance que nous accordons à cette mesure de l'orientation.

Dans le cas où les orientations sont définies modulo π , cette représentation vectorielle ne satisfait pourtant ni le critère d'unicité, ni celui d'équivariance. En effet deux vecteurs de sens opposés peuvent représenter la même orientation (modulo π) et un faible écart angulaire peut se traduire par une variation brutale du vecteur de représentation (comme par exemple le passage de l'angle 90° à l'angle -89°)

La méthode proposée pour pallier ces défauts consiste à représenter l'orientation par le vecteur d'angle double [Mar 72] :

$$\vec{V}_D(x, y) = \begin{pmatrix} C \cdot \cos(2\theta(x, y)) \\ C \cdot \sin(2\theta(x, y)) \end{pmatrix} \quad (1.4)$$

Les conditions d'unicité, d'invariance et d'équivariance sont ainsi respectées [Gra 95].

Le principe d'utilisation du vecteur d'angle double se retrouve dans les travaux de Mardia [Mar 72] dans l'algorithme de Rao [Rao 90], dans l'Analyse en Composantes Principales (ACP) [Don 99], ainsi que dans la détermination du Vecteur Directionnel Moyen (VDM) [Ger 97][Ger 03].

1.2.3.3 Représentation tensorielle

Knutsson [Knu 89] a introduit la représentation tensorielle de l'orientation.

L'orientation en chaque point est représentée par un tenseur d'orientation T , défini par :

$$T(x, y) \equiv \vec{V}(x, y) \cdot \vec{V}(x, y)^T = \begin{pmatrix} C^2 \cdot \cos^2(\theta(x, y)) & C^2 \cdot \cos(\theta(x, y)) \cdot \sin(\theta(x, y)) \\ C^2 \cdot \cos(\theta(x, y)) \cdot \sin(\theta(x, y)) & C^2 \cdot \sin^2(\theta(x, y)) \end{pmatrix} \quad (1.5)$$

où \vec{V} est le vecteur d'orientation $\vec{V}(x, y) = C \begin{pmatrix} \cos(\theta(x, y)) \\ \sin(\theta(x, y)) \end{pmatrix}$ avec C sa norme (1.3).

La norme C du vecteur d'orientation représente la confiance de l'estimation de l'orientation. La représentation tensorielle respecte les propriétés d'unicité, d'invariance et d'équivariance [Knu 89][Nor 93][Gra 95].

1.2.4 Visualisation de l'orientation

1.2.4.1 Objectifs de la visualisation

La représentation vectorielle et la représentation tensorielle de l'orientation sont appropriées lorsqu'il s'agit de mener des calculs sur les champs d'orientation. Cependant ces représentations ne permettent pas d'observer à l'œil nu l'orientation en chaque point d'une image. Nous devons par conséquent trouver d'autres moyens de visualiser des orientations.

Pour pouvoir interpréter aisément l'orientation, il est préférable que les modes de visualisation utilisés respectent les critères d'unicité, d'invariance et d'équivariance.

1.2.4.2 Visualisation par superposition d'indicateurs d'orientation

En nous inspirant de la représentation vectorielle de l'orientation, nous pouvons obtenir une visualisation des orientations locales par des vecteurs placés selon une grille régulière sur l'image (Fig. 1.23). La direction et le sens de ces vecteurs représentent l'orientation locale et la norme des vecteurs correspond à la confiance associée.

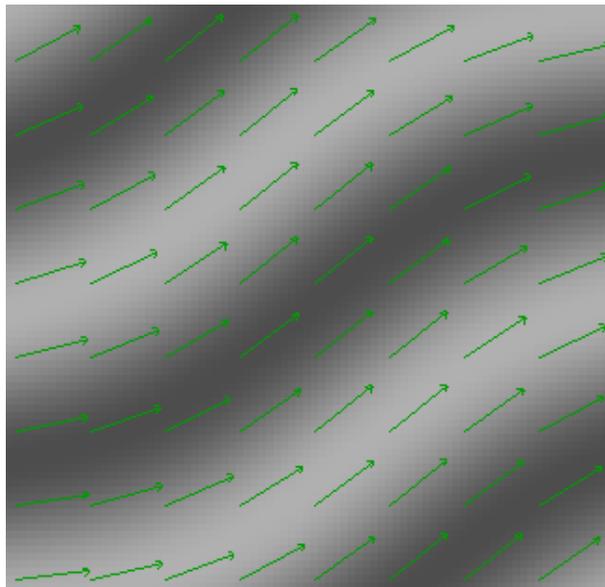


Fig. 1.23 Champ de vecteur associé à l'orientation de l'image

Dans l'image présentée en figure 1.23, l'orientation est π -périodique. Par conséquent le sens du vecteur n'a pas de raison d'être. En effet dans ce cas-là, cette méthode de visualisation ne satisfait plus les conditions d'unicité et d'équivariance.

En supprimant l'indication de sens des vecteurs, nous construisons un champ de directeurs, uniquement définis par leur norme (correspondant à la confiance de l'orientation) et leur direction (associée à l'orientation modulo π). Un tel champ de directeurs permet de visualiser l'orientation locale (Fig. 1.24). Ce mode de visualisation respecte alors les conditions d'unicité et d'équivariance.

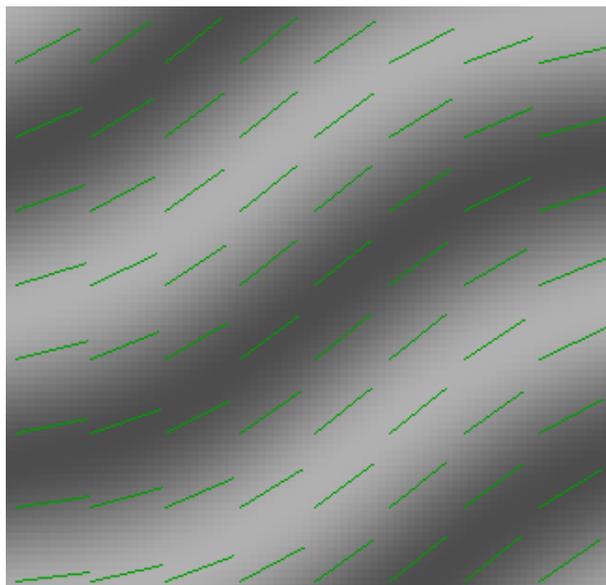


Fig. 1.24 Champ de directeurs associé à l'orientation de l'image

Ainsi, selon que nous souhaitons visualiser des orientations modulo π ou modulo 2π , nous pouvons utiliser respectivement la visualisation des orientations par un champ de directeurs ou de vecteurs.

Néanmoins, quelle que soit la méthode retenue, nous ne pouvons représenter les orientations qu'en certains points choisis au préalable (selon une grille pour les Fig. 1.23 et Fig. 1.24). De plus, les orientations ainsi représentées deviennent difficilement perceptibles lorsque la confiance associée est faible.

1.2.4.3 Cartes d'orientation et de confiance

Nous souhaitons pouvoir visualiser simplement les orientations locales en chaque point de l'image.

Afin de pallier les lacunes de la représentation de l'orientation par un champ de vecteurs ou de directeurs, nous avons choisi de représenter l'orientation par une palette de couleurs circulaire.

Cette représentation colorimétrique circulaire respecte les conditions d'unicité et d'invariance. De plus, nous avons déterminé cette palette de manière à respecter autant que possible la condition d'équivariance : une variation d'orientation correspond à une variation de chrominance proportionnelle.

Le principal avantage de cette méthode de représentation de l'orientation est qu'elle permet d'un simple coup d'œil d'évaluer l'orientation en chaque point de l'image. Sur une image où l'orientation est homogène ou varie lentement, il est possible de détecter visuellement des écarts de l'ordre du degré.

Selon que nous représentons l'orientation modulo π ou modulo 2π , nous utilisons une palette de couleurs de périodicité adaptée (Fig. 1.25).

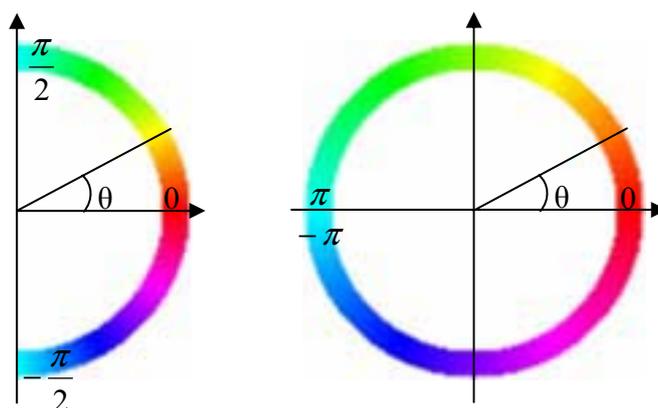


Fig. 1.25 Palettes demi-circulaire et circulaire de représentation de l'orientation

Grâce à cette palette de couleur, nous pouvons établir une carte représentant l'orientation locale d'une image (Fig. 1.26)

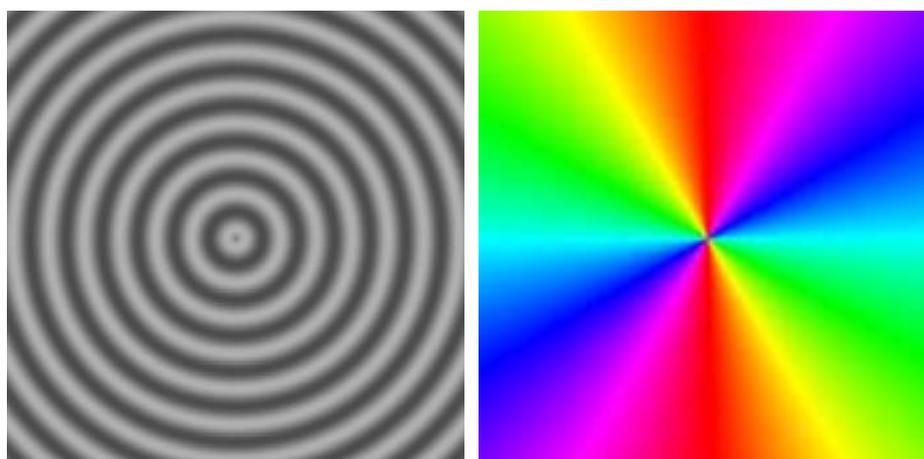


Fig. 1.26 Image et carte d'orientation associée (modulo π)

Nous avons vu précédemment que l'orientation n'existe pas forcément en tout point d'une image.

Nous pouvons donc associer à chaque carte d'orientation une carte de confiance binaire qui quantifie la présence ou l'absence d'orientation en un point donné de l'image étudiée.

Par la suite, cette carte de confiance nous permettra également de représenter la confiance attribuée à l'estimation de l'orientation. Cette carte de confiance variera continûment du noir pour la valeur 0 (pas d'orientation mesurable au point considéré) au blanc pour la valeur 1 (bonne confiance en l'estimation de l'orientation au point considéré).

La figure 1.27-a correspond une image bruitée présentant une orientation de 30° , mais avec une confiance variable. La carte d'orientation théorique de cette image est présentée en figure 1.27-b, en utilisant la palette de couleur demi-circulaire. La figure 1.27-c correspond à une telle carte de confiance associée à l'orientation de l'image. Notons que la carte de confiance dépend de la méthode utilisée pour l'estimation de l'orientation.

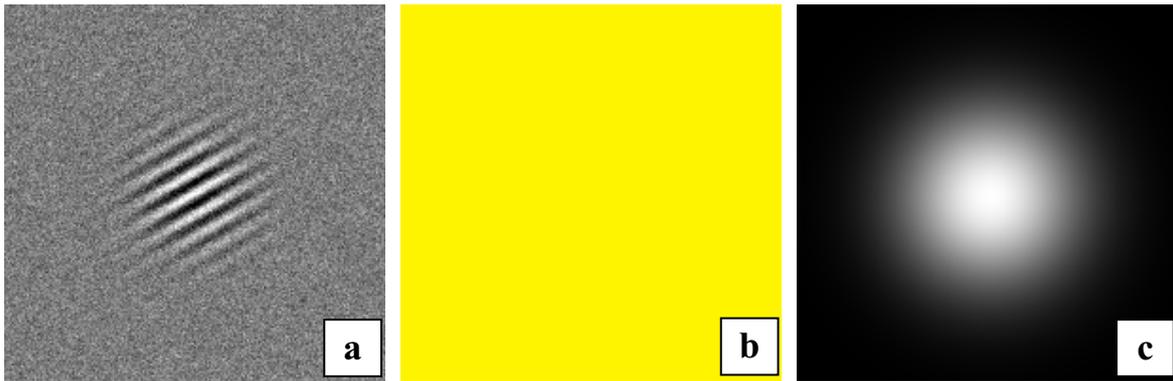


Fig. 1.27 Image bruitée (a), orientation théorique (b) et confiance associée (c).

1.2.4.4 Visualisation des orientations multiples

De la même manière que pour les orientations simples, il est possible de visualiser les orientations multiples par plusieurs vecteurs ou plusieurs directeurs. Nous sommes cependant confrontés à la même lacune que précédemment, à savoir l'impossibilité de visualiser l'orientation en tout point de l'image.

Il est également envisageable d'associer à une image plusieurs cartes colorimétriques d'orientation et les cartes de confiance associées, chacune des cartes d'orientation présentant une orientation en chaque point. Néanmoins les points où apparaissent plusieurs orientations sont généralement épars sur l'image [Kri 96]. Les cartes d'orientations, censées représenter une orientation en chaque point, ont donc peu de signification. Elles sont inadaptées à la visualisation des orientations multiples.

L'étude des voisinages présentant plusieurs orientations est cependant essentielle à la caractérisation de certaines images [And 91] [Kri 96]. Nous devons donc être en mesure de visualiser de façon simple les orientations présentes dans ces voisinages.

La méthode qui vient le plus naturellement à l'esprit pour pouvoir observer l'estimation des orientations multiples en un point précis de l'image consiste à tracer, pour un point donné, la réponse angulaire de l'opérateur d'estimation de l'orientation.

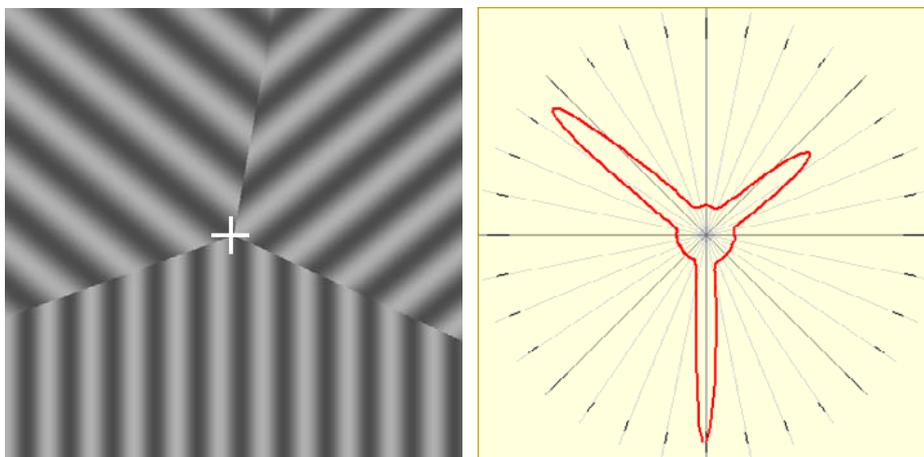


Fig. 1.28 Exemple de réponse angulaire en un point présentant plusieurs orientations.

Selon que nous procédons à une estimation de l'orientation modulo π ou modulo 2π , nous traçons la réponse angulaire entre $-\pi/2$ et $\pi/2$ ou entre $-\pi$ et π respectivement.

La figure 1.28 présente la réponse angulaire d'un opérateur d'estimation des orientations locales (il s'agit de notre opérateur, qui est présenté dans le chapitre 2) en un point particulier de l'image présentant plusieurs orientations. Les modes de cette réponse angulaire correspondent aux orientations locales recherchées.

Nous détaillons les méthodes d'analyse de cette réponse angulaire en Annexe D.

Si nous souhaitons représenter toutes les orientations en chaque point de l'image, il est également possible d'utiliser l'espace d'orientation, introduit par Chen et al. [Che 98]. Cette représentation est également utilisée par Ben-Shahar et al. [Ben 03].

Cette représentation consiste en un espace 3-D déterminé par les axes initiaux de l'image et un axe de profondeur correspondant à l'orientation.

Les conditions d'unicité et d'équivariance ne sont pas respectées dans cet espace d'orientation.

Néanmoins une telle représentation est propice à la séparation des orientations, par exemple en procédant à une segmentation 3-D [Che 98].

1.3 Estimation des orientations locales

Nous étudions ici les principales méthodes d'estimation des orientations locales en tout point d'une image.

Certaines de ces méthodes estiment l'orientation des lignes ou des contours par l'étude des variations locales de l'intensité de l'image. C'est le cas notamment pour les méthodes dérivatives. Toutefois, ces méthodes ne permettent de détecter qu'une seule orientation en chaque point.

D'autres approches se basent sur l'utilisation d'un banc de filtres orientés, réalisant une partition de l'espace fréquentiel. L'intensité de la réponse de ces différents filtres renseigne sur l'existence d'une ou plusieurs orientations en un point.

La convolution des filtres en chaque point de l'image détermine en effet une réponse angulaire et cette réponse angulaire peut présenter plusieurs modes distincts, chacun correspondant à une orientation parmi les orientations locales recherchées.

1.3.1 Méthodes dérivatives

1.3.1.1 Principe

Le calcul des dérivées d'une image continue permet de détecter les contours et leur orientation. Les dérivées partielles g_x et g_y suivant les axes x et y de l'image constituent les composantes du vecteur gradient \vec{G} :

$$\vec{G}(x, y) = \begin{cases} g_x(x, y) = \frac{\partial I(x, y)}{\partial x} \\ g_y(x, y) = \frac{\partial I(x, y)}{\partial y} \end{cases} \quad (1.6)$$

Puisque l'argument du vecteur gradient indique l'axe de plus grande variation des niveaux de gris de l'image, la direction perpendiculaire au vecteur gradient constitue une estimation $\hat{\theta}$ de l'orientation de l'image :

$$\hat{\theta}(x, y) = \arctan\left(\frac{g_y(x, y)}{g_x(x, y)}\right) - \frac{\pi}{2} \text{ modulo } \pi \quad (1.7)$$

soit

$$\hat{\theta}(x, y) = -\arctan\left(\frac{g_x(x, y)}{g_y(x, y)}\right) \text{ modulo } \pi \quad (1.8)$$

Le module du vecteur gradient permet de déterminer un indicateur de confiance de l'estimation de l'orientation. En effet dans les zones de crêtes et de vallées le module du vecteur gradient s'annule et l'estimation de l'orientation par le gradient n'est alors plus calculable en théorie, malgré le fait que l'orientation puisse être perçue sans ambiguïté dans ces zones.

1.3.1.2 Estimation de la dérivée première

Du fait du caractère discret des images numériques, les dérivées ne peuvent être calculées mais doivent être estimées.

L'estimation de chacune des composantes du gradient peut se faire par la convolution sur l'image f de masques M de filtres à réponse impulsionnelle finie, centrés sur le pixel (x, y) considéré :

$$\hat{G}(x, y) = \begin{cases} \hat{g}_x(x, y) = M_x * I(x, y) = \sum_i \sum_j m_x(i, j) I(x-i, y-j) \\ \hat{g}_y(x, y) = M_y * I(x, y) = \sum_i \sum_j m_y(i, j) I(x-i, y-j) \end{cases} \quad (1.9)$$

Le masque du filtre M_y est la rotation d'angle $\frac{\pi}{2}$ du masque M_x .

Le filtre de masque M effectuée, sur un voisinage local autour du point considéré, un calcul des différences finies dans l'axe de dérivation. En général un tel masque procède également à un lissage selon l'axe perpendiculaire à l'axe de dérivation afin de réduire l'influence du bruit.

Les gradients de Prewitt et Sobel, décomposables en (x, y) en un filtre de dérivation (pour détecter les contours) et un filtre de lissage (pour diminuer le bruit), en sont l'illustration.

1.3.1.3 Gradients optimaux de Canny et de Deriche

Dans le cadre de la détection de contours, Canny [Can 83] a défini des critères d'optimisation pour la conception d'un opérateur gradient. Son objectif était de détecter de manière optimale un contour de type échelon perturbé par un bruit blanc gaussien. Les critères qu'il a défini sont : la précision de la localisation du contour, la robustesse au bruit et la faible multiplicité des réponses dues au bruit.

Faute d'obtenir une solution analytique, Canny propose une solution sous optimale à ce problème en effectuant une troncature de filtres à réponse impulsionnelle infinie.

Une solution optimale respectant ces trois critères a été proposée par Deriche [Der 90] sous la forme d'un filtre à réponse impulsionnelle infinie, implantable récursivement. Ce filtre est séparable en x et en y sous la forme d'un filtre de dérivation d et d'un filtre de lissage l appliqué perpendiculairement au filtre de dérivation :

$$\begin{cases} d(x) = c_d \cdot (1 + \alpha|x|) \cdot \exp(-\alpha|x|) \\ l(x) = c_l \cdot x \cdot \exp(-\alpha|x|) \end{cases} \quad (1.10)$$

$$\text{avec } \begin{cases} c_d = \frac{(1 - \exp(-\alpha))^2}{\exp(-\alpha)} \\ c_l = \frac{(1 - \exp(-\alpha))^2}{1 + 2\alpha \exp(-\alpha) - \exp(-2\alpha)} \end{cases}$$

Bien que le gradient de Deriche soit un filtre à réponse impulsionnelle infinie, le paramètre α est assimilable à un réglage de l'échelle d'analyse.

Ainsi, une grande valeur de α permet l'estimation de l'orientation à une échelle locale alors qu'une valeur faible de α conduit à une analyse à grande échelle.

Les composantes du vecteur gradient \vec{G} au point (x, y) de l'image I sont donc :

$$\vec{G}(x, y) = \begin{cases} g_x(x, y) = (d(x)l(y)) * I(x, y) \\ g_y(x, y) = (d(y)l(x)) * I(x, y) \end{cases} \quad (1.11)$$

Notons que les critères d'optimalité retenus par Canny et Deriche reposent sur la détection et la localisation de contours dans le cas d'un échelon bruité. Néanmoins, aucun critère concernant l'estimation de l'orientation n'a été pris en compte lors de sa conception. Utilisé pour estimer l'orientation sur une image de fonction profil sinusoïdale, le gradient de Deriche présente un biais d'estimation non nul [LeP 03].

1.3.1.4 Opérateurs GOP et VOP

Se basant sur le fait que la plupart des opérateurs différentiels ne sont pas optimisés pour l'estimation de l'orientation et que ces opérateurs ne permettent pas l'estimation de l'orientation aux points où leur module est nul, Le Pouliquen [DaC 01][LeP 03] propose de nouveaux opérateurs optimisés vis-à-vis du biais d'estimation de l'orientation et de l'immunité au bruit blanc.

Ces opérateurs consistent en un opérateur GOP, de type gradient, qui estime les variations linéaires du signal, et un opérateur VOP, de type vallonnement fondé sur les variations quadratiques du signal.

L'opérateur GOP estime l'orientation en déterminant la direction perpendiculaire à l'axe de plus grande pente.

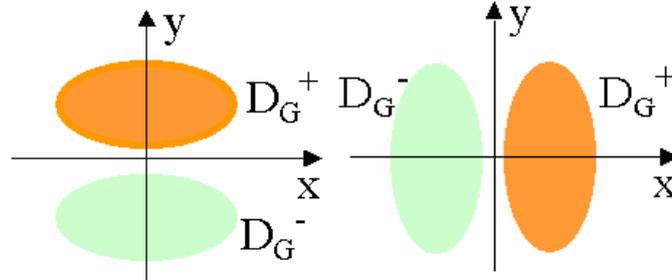


Fig. 1.29 Domaines de définition des coefficients des masques GOP

L'estimateur du gradient GOP se présente sous la forme de deux masques M_{G_x} et M_{G_y} . Les coefficients de M_{G_x} sont placés en respectant un axe d'anti-symétrie horizontal et un axe de symétrie vertical. Les coefficients du masque sont positifs dans le domaine D_G^+ .

Une fois les masques de l'opérateur GOP convolués à l'image, l'estimation de l'orientation est identique à celle des autres opérateurs de type gradient :

$$\vec{G}(x, y) = \begin{cases} g_x(x, y) = (d(x).l(y)) * I(x, y) \\ g_y(x, y) = (d(y).l(x)) * I(x, y) \end{cases} \quad (1.12)$$

$$\text{avec } \begin{cases} gop_x(x, y) = M_{G_x} * I(x, y) \\ gop_y(x, y) = M_{G_y} * I(x, y) \end{cases}$$

Si on considère le modèle de texture $f(x, y) = h(x.\sin(\theta_0) + y.\cos(\theta_0))$, on peut déterminer gop_x et gop_y en utilisant le développement en série de Taylor de h au pixel (x_0, y_0) .

Les développements de Taylor de gop_x et gop_y limités à l'ordre n permettent de déterminer des conditions de non biais pour des textures de fonctions génératrices polynomiales d'ordre inférieur ou égal à n et pour un estimateur de l'orientation de type gradient, à réponse impulsionnelle finie et de masque M_{G_x} . L'ordre n maximal dépend de la taille du masque de convolution retenu.

Comme les autres opérateurs qui estiment la dérivée première, l'opérateur GOP a un module très faible voire nul dans les zones de pics, de crêtes ou de vallées de l'image et est donc inadapté à l'estimation de l'orientation en ces points.

L'opérateur VOP va estimer l'orientation en déterminant l'axe de plus faible vallonnement. A l'inverse des opérateurs du premier ordre, son estimation de l'orientation est précise dans les zones de crêtes et de vallées, mais l'opérateur VOP n'est pas adapté aux zones d'inflexion de l'image.

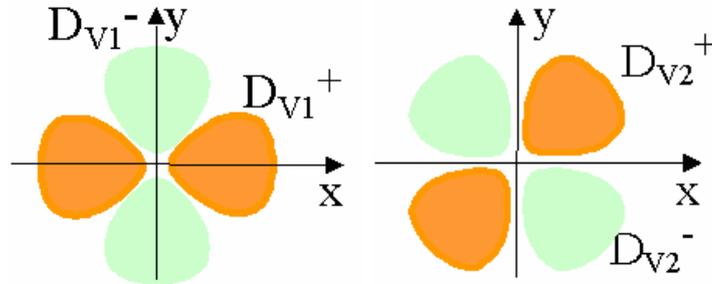


Fig. 1.30 Domaines de définition des coefficients des masques VOP

Comme pour l'estimateur du gradient, l'estimateur du vallonnement VOP se présente sous la forme de deux masques M_{V_1} et M_{V_2} . Le premier masque M_{V_1} estime les variations quadratiques selon les axes principaux x et y , et le deuxième masque M_{V_2} effectue cette estimation selon les bissectrices de ces axes.

L'estimation de l'orientation par le vallonnement se fait alors modulo $\pi/2$ par :

$$\hat{\theta}_{VOP}(x, y) = \frac{1}{2} \arctan\left(\frac{vop_2(x, y)}{vop_1(x, y)}\right) \text{ modulo } \frac{\pi}{2} \quad (1.13)$$

$$\text{avec } \begin{cases} vop_1(x, y) = M_{V_1} * I(x, y) \\ vop_2(x, y) = M_{V_2} * I(x, y) \end{cases}$$

Pour lever l'indétermination et obtenir une estimation de l'orientation à π près, il suffit de tester l'écart du modèle avec le voisinage local de l'image.

Comme pour l'opérateur GOP, le développement en série de Taylor limité à l'ordre n de vop_1 et de vop_2 permet d'établir les conditions de non biais pour des textures de fonction génératrice polynomiale d'ordre inférieur ou égal à n et pour un estimateur de l'orientation de type vallonnement, à réponse impulsionnelle finie et de masques M_{V_1} et M_{V_2} . Une fois encore, l'ordre maximal n dépend de la taille des masques choisis.

Des exemples de masques de convolution des opérateurs GOP et VOP sont présentés en Annexe B.

Les masques GOP et VOP peuvent être combinés de façon à fournir une estimation de l'orientation en tout point, les deux étant complémentaires en ce qui concerne les zones où ils sont capables de fournir une estimation de l'orientation [LeP 03].

1.3.1.5 Bilan des approches dérivatives

Les approches dérivatives, qui ne calculent que les deux composantes du gradient local ou du vallonnement local, sont peu coûteuses en temps de calcul.

Par l'estimation du vecteur gradient, les méthodes fondées sur la dérivée première déterminent l'axe de plus grande variation locale de l'image et en déduisent l'orientation, qui est perpendiculaire à la direction du gradient. Ces méthodes ne peuvent donc estimer qu'une seule orientation en chaque point. Il en va de même pour les méthodes estimant le vallonnement local.

De plus, lorsque deux orientations (ou plus) coexistent en un même point, l'estimation de l'orientation fournie par les méthodes dérivatives ne correspondra à aucune des orientations présentes mais à une combinaison non significative de celles-ci.

Ainsi, les méthodes dérivatives, qui déterminent l'axe de plus grande variation linéaire ou quadratique du signal, ne sont pas adaptées à l'estimation d'orientations multiples.

Par ailleurs, dans le cas d'une image correspondant à notre modèle de fonction profil h sinusoïdale (Eq. 1.2), aucune de ces méthodes ne fournit d'estimation non biaisée en tout point de l'image. Sur une telle image, il est même possible de démontrer que le biais d'estimation est indépendant de la position étudiée dans l'image [LeP 03].

1.3.2 Approches utilisant des filtres orientés

Pour déterminer l'orientation locale, le principe des filtres orientés consiste à convoluer l'image avec un banc de filtres orientés.

L'analyse de la réponse angulaire qui en découle permet de déterminer non seulement l'orientation principale en chaque point de l'image mais également d'éventuelles orientations secondaires.

Un banc de filtres orientés est constitué des N rotations d'un filtre de base $F(x, y)$:

$$F^\theta(x, y) = F(x \cdot \cos(\theta) - y \cdot \sin(\theta), x \cdot \sin(\theta) + y \cdot \cos(\theta)) \quad (1.14)$$

En général le filtre de base $F(x, y)$ résulte d'une fonction génératrice f développée selon la direction horizontale et pondérée par une fonction w :

$$F(x, y) = f(y) \cdot w(x, y) \quad (1.15)$$

Le masque d'apodisation w est souvent gaussien, ce qui permet une bonne localisation à la fois dans le domaine spatial et fréquentiel.

De la même manière que pour les gradients optimaux, le filtre $F(x, y)$ peut être conçu de manière à réagir plus particulièrement à certaines structures de l'image, comme les contours ou les lignes.

Le choix du nombre N de filtres ainsi que du filtre $F(x, y)$ dépend du contexte dans lequel s'effectue l'estimation de l'orientation.

1.3.2.1 Filtres en quadrature

Lors du processus d'estimation de l'orientation par des filtres orientés, le choix du filtre n'est pas sans conséquence sur la qualité de la réponse angulaire en certains points de l'image.

Ainsi, les filtres d'estimation de l'orientation ne comportant qu'un seul masque par orientation sont en général sensibles à la phase locale de l'image [Gra 95].

Un filtre conçu pour répondre aux zones de contours fournira souvent une réponse erronée dans les zones de crêtes et de vallées, et inversement un filtre sensible aux lignes donnera une estimation biaisée dans les zones d'inflexion de l'image. En effet, le produit de convolution de ces filtres dans ces zones de l'image est quasiment nul, quelle que soit l'orientation locale de l'image.

Une solution à ce problème est de combiner les réponses de ces deux types de filtres, chacun fournissant une réponse correcte dans les configurations appropriées.

L'utilisation de filtres en quadrature [Ade 85][Knu 89][And 91][Gra 95] permet d'obtenir une estimation indépendante de la phase et répond donc à ces considérations.

Les filtres en quadrature ont pour principe d'extraire l'énergie radiale $E(\varphi)$ dans l'espace fréquentiel.

Dans l'espace fréquentiel, un filtre en quadrature correspond à la somme d'un filtre pair et d'un filtre impair [And 91]. En coordonnées polaires, cette somme s'exprime par :

$$F(\rho, \varphi) = F_p(\rho, \varphi) + F_i(\rho, \varphi) = W(\rho)\Gamma(\varphi - \varphi_0) \quad (1.16)$$

$$\begin{cases} F_p(\rho, \varphi) = \frac{1}{2}W(\rho)(\Gamma(\varphi - \varphi_0) + \Gamma(\varphi - \varphi_0 + \pi)) \\ F_i(\rho, \varphi) = \frac{1}{2}W(\rho)(\Gamma(\varphi - \varphi_0) - \Gamma(\varphi - \varphi_0 + \pi)) \end{cases} \quad (1.17)$$

La fonction $W(\rho)$ définit les caractéristiques fréquentielles du filtre en quadrature. L'angle φ_0 détermine l'orientation du filtre. Enfin la fonction $\Gamma(\varphi)$ contrôle la sélectivité angulaire du filtre.

Pour chaque orientation θ_k testée, la réponse d'une paire de filtres en quadrature est obtenue par :

$$R(\theta_k) = R_p(\theta_k) + i.R_i(\theta_k) \quad (1.18)$$

$R_p(\theta_k)$ et $R_i(\theta_k)$ correspondent respectivement aux réponses des filtres pair et impair.

Nous nous intéressons plus particulièrement à l'énergie de cette réponse :

$$|R(\theta_k)| = \sqrt{(R_p(\theta_k))^2 + (R_i(\theta_k))^2} \quad (1.19)$$

Il est également possible de calculer l'argument $Arg(R(\theta_k))$ afin de déterminer la forme (ligne ou contour) du voisinage dans la direction étudiée.

Notons d'autre part que dans le domaine spatial, à partir d'un filtre pair $F_p(x, y)$ de fonction génératrice f_p , il est possible de déterminer le filtre impair $F_i(x, y)$ de fonction génératrice f_i qui lui est associé, en opérant un changement de phase de 90° de f_p . Ce changement de phase est obtenu en calculant la transformée de Hilbert de f_p (ou son approximation numérique) : $f_i = H(f_p)$.

L'estimation de l'orientation par de tels filtres est néanmoins très coûteuse en temps de calcul, car pour chaque point de l'image, il faut convoluer $2N$ filtres pour obtenir la réponse angulaire.

Pour une image I de dimensions $D_{I,x}$ et $D_{I,y}$, et des filtres ayant un support de calcul de taille M , le coût calculatoire est par conséquent égal à : $D_{I,x} \cdot D_{I,y} \cdot 2N \cdot M^2 \cdot (Mult + Add)$.

Les grandeurs *Mult* et *Add* représentent respectivement le coût calculatoire d'une multiplication et d'une addition.

Les filtres de Gabor, les filtres steerable, l'approximation des filtres steerable ainsi que les filtres wedge steerable appartiennent à la classe des filtres en quadrature.

1.3.2.2 Filtres de Gabor

Un banc de filtres de Gabor partitionne les orientations dans l'espace fréquentiel autour d'une fréquence ρ_0 donnée.

La réponse de ce banc de filtres orientés est une fonction de l'orientation φ_F lorsque les autres paramètres sont fixés. Cette réponse correspond à l'énergie radiale contenue dans une bande de fréquences donnée. [Big 94]

Dans l'espace de Fourier, le filtre de Gabor $G(u, v)$ se traduit par une gaussienne centrée sur la fréquence ρ_0 , d'ouverture radiale σ_ρ et d'ouverture angulaire σ_φ (Fig. 1.31).

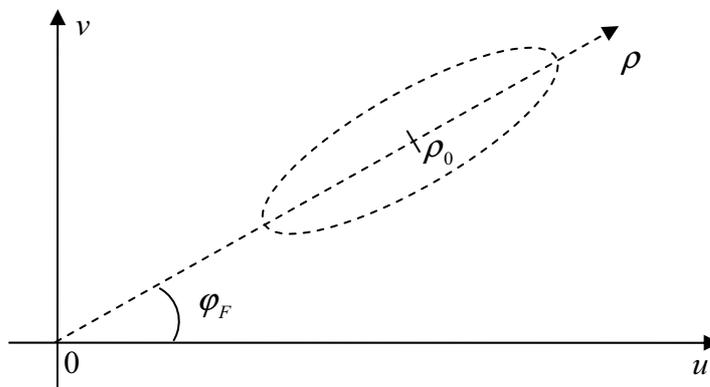


Fig. 1.31 Construction des filtres de Gabor dans le domaine de Fourier

Le filtre de Gabor d'orientation φ_F s'obtient par rotation de cette gaussienne autour de l'origine. L'expression du filtre de Gabor d'orientation φ_F en coordonnées polaires est donc :

$$G^\theta(\rho, \varphi) = \frac{1}{2\pi\sigma_\rho\sigma_\varphi} \exp\left(-\left(\frac{(\rho-\rho_0)^2}{2\sigma_\rho^2} + \frac{(\varphi-\varphi_F)^2}{2\sigma_\varphi^2}\right)\right) \quad (1.20)$$

Ce gabarit énergétique correspond à la somme de deux filtres. Dans le domaine, cette paire de filtres comprend un filtre G_p^θ réel pair et un filtre G_i^θ imaginaire impair :

$$\begin{aligned} G_p^\theta(x_\theta, y_\theta) &= \cos(2\pi\rho_0 y_\theta) \exp\left(-\left(\frac{\sigma_\rho^2 x_\theta^2}{2} + \frac{\sigma_\varphi^2 y_\theta^2}{2}\right)\right) \\ G_i^\theta(x_\theta, y_\theta) &= \sin(2\pi\rho_0 y_\theta) \exp\left(-\left(\frac{\sigma_\rho^2 x_\theta^2}{2} + \frac{\sigma_\varphi^2 y_\theta^2}{2}\right)\right) \end{aligned} \quad (1.21)$$

avec :

$$\begin{cases} x_\theta = x \cdot \cos(\theta) - y \cdot \sin(\theta) \\ y_\theta = x \cdot \sin(\theta) + y \cdot \cos(\theta) \end{cases}$$

Notons que le filtre spatial d'angle θ correspond au filtre fréquentiel d'angle $\varphi_F + \pi$.

Il est également possible de noter l'expression du filtre en fonction de ses ouvertures spatiales, ou plus exactement d'une des deux ouvertures et d'un facteur de forme λ :

$$\begin{aligned} G_p^\theta(x_\theta, y_\theta) &= \cos(2\pi\rho_0 y_\theta) \exp\left(-\left(\frac{x_\theta^2 + \lambda^2 y_\theta^2}{2\lambda^2 \sigma^2}\right)\right) \\ G_i^\theta(x_\theta, y_\theta) &= \sin(2\pi\rho_0 y_\theta) \exp\left(-\left(\frac{x_\theta^2 + \lambda^2 y_\theta^2}{2\lambda^2 \sigma^2}\right)\right) \end{aligned} \quad (1.22)$$

Nous avons donc les relations $\sigma = \frac{1}{\sigma_\rho}$ et $\lambda = \frac{\sigma_\rho}{\sigma_\varphi}$.

La figure 1.32 représente les masques de convolution d'une paire de filtres de Gabor orientés à $\theta = -60^\circ$ pour lesquels $\lambda = 3$.

Choix des paramètres

- Pour des considérations calculatoires, les filtres spatiaux sont fenêtrés, et tronqués à une taille de masque de $M \times M$ pixels (avec M impair).

La sélectivité angulaire du banc de filtres est déterminée par σ_φ . Ce paramètre sera choisi aussi petit que possible en fonction de la taille désirée M du masque et du nombre N de filtres calculés. Afin de partitionner toutes les orientations dans l'espace des fréquences, il convient

d'avoir $\sigma_\varphi \geq \frac{\pi \cdot u_0}{2N}$.

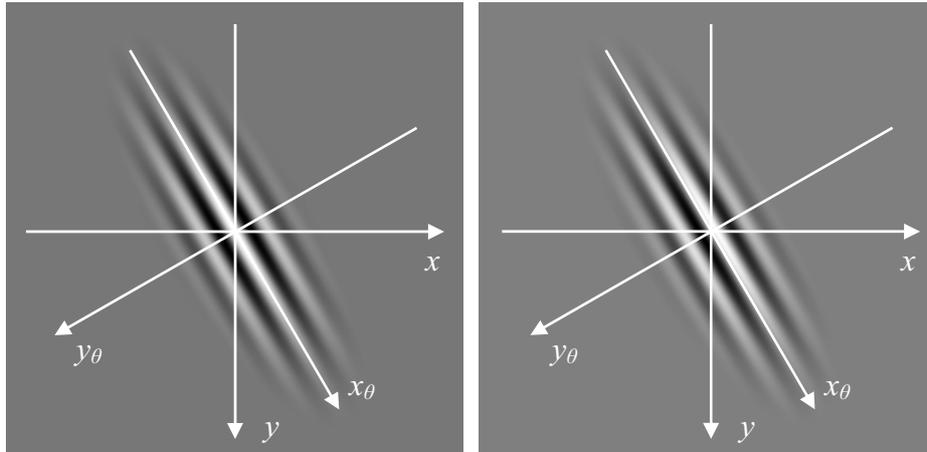


Fig. 1.32 Paire de filtres de Gabor orientés à $\theta = -60^\circ$ avec $\lambda = 3$

- La fréquence centrale ρ_0 détermine la plage de fréquences dans laquelle vont opérer les filtres de Gabor, et le paramètre σ_ρ détermine la largeur de cette plage de fréquences.

De plus, afin d'être moins tributaire du réglage de la fréquence centrale ρ_0 il convient d'avoir σ_ρ le plus grand possible.

- Nous choisissons un rapport $r_M = M/\sigma_M$ entre la taille M du masque de convolution du filtre et la plus grande ouverture spatiale $\sigma_M = \max(1/\sigma_\rho, 1/\sigma_\varphi) = \max(\sigma, \lambda\sigma)$ de l'enveloppe gaussienne du filtre. Il convient donc d'avoir $\sigma_M \leq \frac{M}{r_M}$.

En général l'élongation λ est telle que $\lambda \geq 1$, cette relation devient donc : $\sigma \leq \frac{M}{\lambda \cdot r_M}$

Généralement, il est conseillé de choisir de choisir $r_M \geq 5$ afin de conserver suffisamment d'énergie de la gaussienne à l'intérieur du masque fenêtré.

- Nous souhaitons également avoir au moins une période de la sinusoïde de fréquence ρ_0 (et donc de période $T_0 = 1/\rho_0$) qui soit peu atténuée par l'enveloppe gaussienne. Il est donc nécessaire de prendre $\sigma \geq \frac{r_\sigma}{\rho_0}$ (ou $\sigma \geq r_\sigma \cdot T_0$), avec $r_\sigma = 0.5$ typiquement.

Le choix des paramètres ρ_0 , σ_ρ et σ_φ dans le domaine fréquentiel (ou des paramètres σ , λ , et M) relève donc d'un compromis entre le réglage en fréquence, la sélectivité angulaire et la taille désirée du masque de convolution du filtre.

L'implantation étant identique à celle des filtres en quadrature, l'estimation de l'orientation par des filtres de Gabor est très coûteuse en temps de calcul.

Pour une image I de dimensions $D_{I,x}$ et $D_{I,y}$, et des filtres ayant un support de calcul de taille M , le coût calculatoire est par conséquent égal à : $D_{I,x}.D_{I,y}.2N.M^2.(Mult + Add)$.

Les grandeurs $Mult$ et Add représentent respectivement le coût calculatoire d'une multiplication et d'une addition.

1.3.2.3 Filtres Steerable

Freeman et Adelson [Fre 91] proposent de déterminer la réponse pour n'importe quel angle à partir des réponses à un faible nombre de filtres de base. Pour cela ils introduisent des filtres en quadrature dits 'steerable' pour lesquels il est possible de reconstruire théoriquement de manière exacte le filtre correspondant à n'importe quelle orientation à partir de la combinaison linéaire de quelques filtres de base.

L'exemple typique utilisé pour expliquer le principe des filtre Steerable est le filtre S_1 correspondant à la dérivée première selon un axe d'une gaussienne 2-D.

Ce filtre, lorsque l'on calcule la dérivée selon l'axe des abscisses x , a pour expression :

$$S_1^{0^\circ}(x, y) = -x \cdot \exp\left(-\frac{x^2 + y^2}{2}\right) \quad (1.23)$$

La dérivée selon l'axe y nous conduit à l'expression correspondant à la rotation de 90° du filtre précédent :

$$S_1^{90^\circ}(x, y) = -y \cdot \exp\left(-\frac{x^2 + y^2}{2}\right) \quad (1.24)$$

Dans ce cas, le filtre S_1^θ , orienté dans la direction quelconque θ s'obtient par combinaison linéaire des deux précédents filtres :

$$S_1^\theta(x, y) = \cos(\theta).S_1^{0^\circ}(x, y) + \sin(\theta).S_1^{90^\circ}(x, y) \quad (1.25)$$

Nous pouvons ainsi déterminer de manière exacte la réponse sur l'image de ce filtre pour n'importe quelle orientation par simple combinaison linéaire des réponses des filtres $S_1^{0^\circ}$ et $S_1^{90^\circ}$.

Dans le cas général, pour que l'interpolation puisse s'effectuer de manière exacte quelle que soit l'orientation, la condition est que le filtre S^θ orienté d'angle θ puisse s'écrire comme une combinaison linéaire de B filtres de base S^{θ_i} , orientés d'angles θ_i , $i \in [1, B]$:

$$S^\theta(x, y) = \sum_{i=1}^B a_i(\theta).S^{\theta_i}(x, y) \quad (1.26)$$

La réponse du filtre d'angle θ est déterminée par combinaison linéaire des réponses des filtres d'angles θ_i , $i \in [1, B]$.

Tous les filtres ne satisfont pas la condition précédente (Eq. 1.26). Dans le cadre de l'estimation de l'orientation locale, Freeman et Adelson [Fre 91] proposent d'utiliser des filtres de base qui sont le produit d'une fonction génératrice f et d'une fonction de fenêtrage w :

$$S(x, y) = f(y).w(x, y) \quad (1.27)$$

La fonction génératrice f des filtres pairs est une dérivée d'ordre pair d'une gaussienne $f(y) = \frac{\partial^2}{\partial y^2}(g_1(y)) = \frac{\partial^2}{\partial y^2}(\exp(-y^2))$ et la fonction de fenêtrage w est une enveloppe gaussienne circulaire $w(x, y) = g_2(x, y) = \exp(-(x^2 + y^2))$.

Le filtre en quadrature impair associé S_q^θ se déduit de l'approximation polynomiale de la transformée de Hilbert de la fonction génératrice du filtre pair. Ces filtres satisfont la condition (1.26).

Si w est une fenêtre circulaire et f une fonction polynomiale d'ordre n_h , le nombre B de filtres de base nécessaires est $B = 2n_h + 1$. Si de plus f est paire ou impaire, le nombre de filtres de base nécessaires devient $B = n_h + 1$.

Le filtre steerable le plus couramment utilisé a pour fonction génératrice la fonction f paire, correspondant à la dérivée seconde d'une gaussienne [Fre 91]. Les expressions du filtre horizontal de ce filtre et de l'approximation de son filtre en quadrature sont :

$$\begin{cases} S_2^{0^\circ}(x, y) = (2y^2 - 1)\exp(-(x^2 + y^2)) \\ S_{2q}^{0^\circ}(x, y) = (y^3 - 2.254y)\exp(-(x^2 + y^2)) \end{cases} \quad (1.28)$$

Nous pouvons reconstruire ces filtres pour n'importe quelle orientation grâce aux équations de reconstruction :

$$\begin{cases} S_2^\theta(x, y) = \sum_{i=1}^3 a_i(\theta).S_2^{\theta_i}(x, y) \\ S_{2q}^\theta(x, y) = \sum_{j=1}^4 b_j(\theta).S_{2q}^{\theta_j}(x, y) \end{cases} \quad (1.29)$$

$$\text{avec } \begin{cases} a_i(\theta) = \frac{1}{3}[1 + 2\cos(2(\theta - \theta_i))] \\ b_j(\theta) = \frac{1}{4}[2\cos(\theta - \theta_j) + 2\cos(3(\theta - \theta_j))] \end{cases}$$

Les angles θ_i et θ_j sont répartis uniformément entre 0 et π .

La figure 1.33 représente les filtres $S_2^{30^\circ}$ et $S_{2q}^{30^\circ}$.

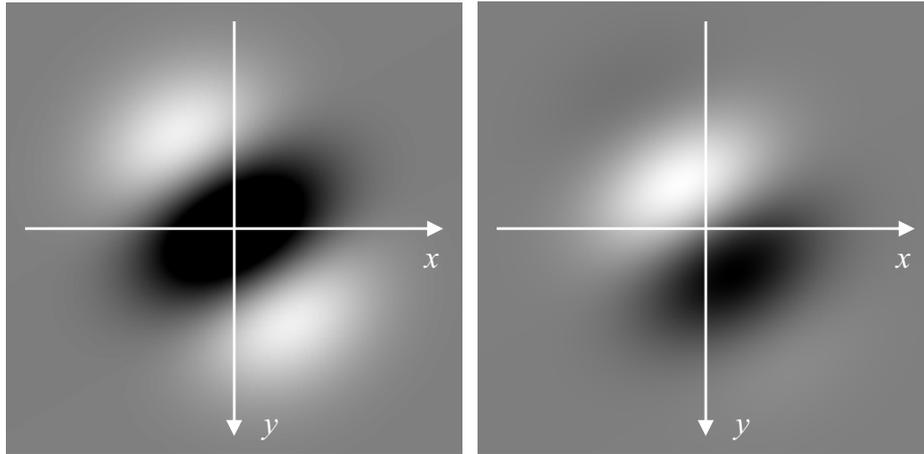


Fig. 1.33 Paire de filtres steerable orientés à 30°

Puisqu'il suffit de convoluer un faible nombre de filtres de base pour retrouver par interpolation la réponse des filtres pour n'importe quel angle, l'utilisation de filtres steerable permet de diminuer le temps de calcul du processus d'estimation de l'orientation par des paires de filtres en quadrature.

La dérivée seconde d'une gaussienne suffit à l'estimation de l'orientation locale principale, mais dans le cadre de l'estimation d'orientations multiples, il est recommandé d'utiliser la dérivée quatrième, qui présente une sélectivité angulaire légèrement plus importante [Fre 91].

Le coût calculatoire des filtres steerable est réduit du fait de l'utilisation d'un nombre réduit de filtres de base : $D_{I,x}.D_{I,y}.2B.M^2.(Mult + Add)$

1.3.2.4 Approximation des filtres steerable

Il est néanmoins difficile d'obtenir une bonne sélectivité angulaire en se contentant d'utiliser des dérivées de gaussiennes d'ordre supérieur. En effet la largeur angulaire des supports fréquentiels de ces dérivées varie peu, et le gain de sélectivité ainsi obtenu est souvent insuffisant [Yu 03].

Afin d'augmenter de façon significative la sélectivité angulaire des filtres steerable, Perona [Per 92] propose l'utilisation de filtres pour lesquels la fonction de fenêtrage w n'est plus isotrope mais lisse davantage dans la direction du filtre :

$$w(x, y) = g_2(x, y) = \exp\left(-\left(\frac{x^2}{\sigma_r^2} + \frac{y^2}{\sigma_\theta^2}\right)\right) \quad (1.30)$$

Néanmoins les filtres ainsi obtenus ne peuvent plus être décomposés comme une somme finie de filtres de base [Per 95]. Les filtres vont donc être approximés par une décomposition en valeurs singulières (SVD) dans une base de fonctions [Per 95][Som 98]. Ces fonctions sont en général choisies séparables en x et y afin de permettre une implantation des filtres moins coûteuse en temps de calcul.

Pour une erreur de reconstruction donnée, le nombre B de filtres de base nécessaire à l'approximation des masques dépend à la fois du degré n_h de la fonction génératrice f et du rapport σ_r/σ_θ [Per 95].

De la même manière que pour les filtres de Gabor, ce rapport $\lambda = \sigma_r/\sigma_\theta$ peut être assimilé à un paramètre d'élongation de l'opérateur.

La figure 1.34 représente l'approximation d'une paire de filtres steerable orientés à 30° avec $\sigma_r/\sigma_\theta = 3$.

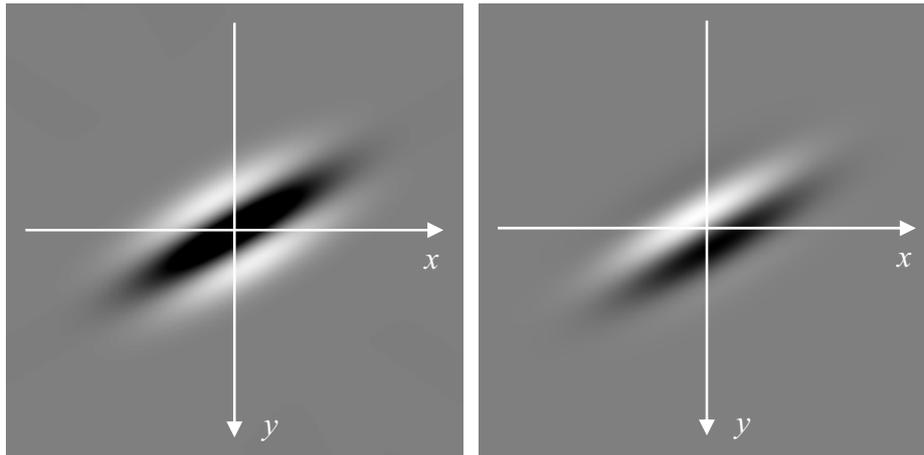


Fig. 1.34 Approximation d'une paire de filtres steerable orientés à 30° avec $\lambda = 3$

1.3.2.5 Filtres Wedge Steerable

Les filtres symétriques ou anti-symétriques fournissent une estimation de l'orientation modulo π et conviennent donc à l'étude d'images présentant une orientation modulo π .

Néanmoins lors de l'estimation d'orientations nous sommes parfois confrontés à des cas où il convient d'estimer l'orientation modulo 2π , comme par exemple lorsqu'il s'agit d'estimer l'orientation à l'extrémité d'une ligne ou lorsque l'on cherche à estimer des orientations multiples modélisables par un processus de juxtaposition.

Les filtres 'wedge steerable', à la fois 'steerable' et asymétriques, apportent une réponse à ce problème [Sim 96]. Comme pour les filtres précédemment exposés, ils se présentent sous la forme d'une paire de filtres en quadrature, avec un filtre pair et un filtre impair.

Les filtres wedge steerable sont décomposables dans le domaine spatial en une fonction radiale w , commune aux deux filtres, et une fonction angulaire f_p pour le filtre pair et f_i pour le filtre impair.

Les fonctions angulaires f_p et f_i sont déterminées de manière à maximiser la sélectivité angulaire de la paire de filtres. Ces fonctions sont identiques à un changement de phase de $\pi/2$ près. Une transformation de Hilbert permet donc de passer de l'une à l'autre.

Ces fonctions angulaires consistent en une somme pondérée de fonctions harmoniques :

$$\begin{aligned} f_p(\theta) &= \sum_{n=1}^N a_n \cdot \cos(n\theta) \\ f_i(\theta) &= \sum_{n=1}^N a_n \cdot \sin(n\theta) \end{aligned} \quad (1.31)$$

Quand N augmente, le mode de la fonction angulaire correspondant à l'orientation détectée devient plus étroit. Le nombre de filtres de base nécessaires est $2N_w$ (N_w filtres pairs et N_w filtres impairs).

Les coefficients a_n sont déterminés de manière à maximiser la sélectivité du filtre. Ceci revient à minimiser le critère :

$$\int \lambda^2(\theta) (f_p^2(\theta) + f_i^2(\theta)) d\theta \quad (1.32)$$

où la fonction λ est strictement croissante. Il est recommandé de choisir $\lambda(\theta) = \theta$ pour simplifier le calcul de minimisation.

En procédant à l'échantillonnage de θ sur M_p points, la minimisation du critère précédent nous conduit à rechercher le vecteur propre $A = (a_1, a_2, \dots, a_N)$ associé à la plus petite valeur propre de la matrice :

$$C^T \Lambda^T \Lambda C + S^T \Lambda^T \Lambda S \quad (1.33)$$

Les matrices C , S et Λ sont définies par :

$$\begin{aligned} c_{ij} &= \cos(2\pi i j / M_p) \\ s_{ij} &= \sin(2\pi i j / M_p) \\ \lambda_{ij} &= \lambda(2\pi i / M_p) \delta_{ij}, \begin{cases} \delta_{ij} = 1 & \text{si } i = j \\ \delta_{ij} = 0 & \text{si } i \neq j \end{cases} \end{aligned} \quad (1.34)$$

Les coefficients harmoniques a_n optimaux en fonction de N_w sont présentés en Annexe C.

Une fois les fonctions angulaires optimales f_p et f_i déterminées, il suffit de les combiner avec la fonction radiale w . Cette fonction peut être choisie arbitrairement sans affecter le caractère steerable des filtres. Le but de cette fonction est de déterminer l'échelle d'analyse du filtre en déterminant la zone où le filtre sera non nul. Un exemple d'une telle fonction est présenté en Annexe C.

Enfin, pour déterminer les fonctions d'interpolation, il suffit d'étudier l'expression du filtre d'orientation quelconque et de l'exprimer comme une combinaison linéaire des filtres de base.

La figure 1.35 présente les masques de convolution d'une paire de filtres wedge steerable avec $N_w = 10$.

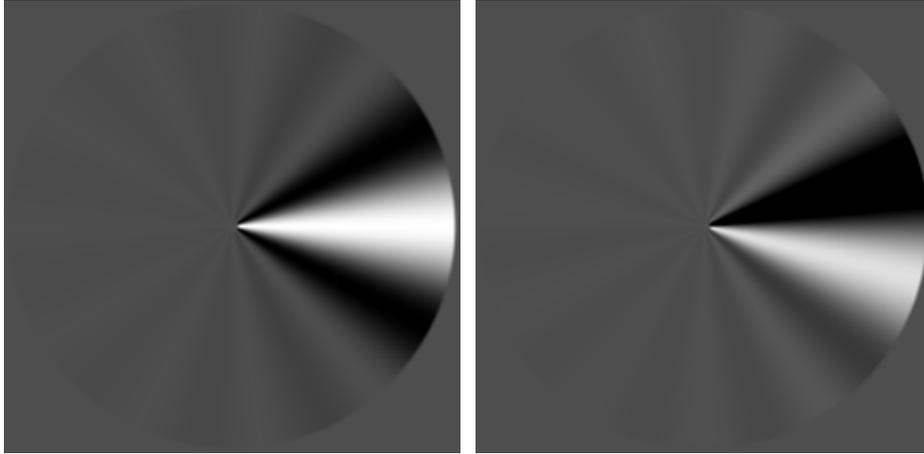


Fig. 1.35 Paire de filtres wedge steerable orientés à 0° ($N_w = 10$)

Comme pour les filtres steerable, le coût calculatoire est diminué par la réduction du nombre de filtres de base : $D_{I,x} \cdot D_{I,y} \cdot 2N_w \cdot M^2 \cdot (Mult + Add)$.

1.3.2.6 Filtres angulaires gaussiens

Yu et al. [Yu 01] introduisent une autre méthode asymétrique pour la détection des orientations multiples. L'objectif de cette méthode est d'obtenir une meilleure résolution angulaire que celle que l'on peut obtenir par les approches précédentes.

Comme pour les filtres wedge steerable, le filtre se décompose comme le produit d'une fonction radiale w et d'une fonction angulaire h . La fonction radiale w est comparable à celle utilisée pour les filtres wedge steerable, et détermine une couronne définie par les rayons R_1 et R_2 , par contre la fonction angulaire h est une gaussienne de paramètre σ_θ et non un produit de fonctions harmoniques (Fig. 1.36).

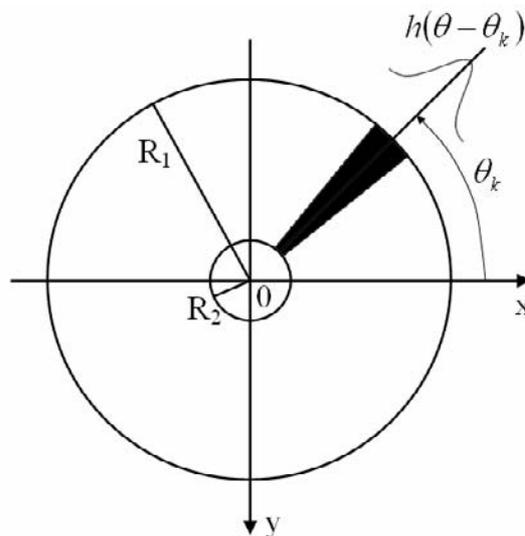


Fig. 1.36 Filtre angulaire gaussien

Les fonctions d'interpolation choisies pour la reconstruction de la réponse $R(\theta)$ à partir des valeurs échantillonnées $R(\theta_k)$ sont des gaussiennes. Cette reconstruction n'est cependant pas exacte et constitue une approximation de la réponse.

La réponse angulaire $R(\theta)$ ainsi obtenue correspond à une moyenne angulaire de l'intensité lumineuse autour du point étudié de l'image. L'analyse directe de cette réponse angulaire permet donc de détecter l'orientation des lignes. De plus, le calcul de la dérivée $DR(\theta) = \left| \frac{\partial}{\partial \theta} R(\theta) \right|$ de cette réponse angulaire permet d'estimer l'orientation des contours.

Pour une même résolution angulaire, cette méthode présente un coût calculatoire moindre que les filtres wedge steerable. Cependant il est impossible de combiner les réponses angulaires $R(\theta)$ et $DR(\theta)$ comme pour une paire de filtres en quadrature [Yu 01]. L'estimation de l'orientation ne peut donc se faire indépendamment de la phase locale de l'image.

Au final cet opérateur se révèle très dépendant du contexte d'estimation choisi. Il nécessite par exemple de déterminer a priori si l'orientation recherchée correspond à l'orientation de lignes claires sur fond sombre, de lignes sombres sur fond clair ou encore à l'orientation des contours.

1.3.2.7 Réseau Orienté de Lignes

Le Pouliquen [LeP 01] propose une autre méthode d'estimation locale de l'orientation permettant de déterminer, à une échelle donnée, l'orientation de la structure allongée correspondant le mieux à un voisinage local.

Comme pour les filtres orientés, l'opérateur est appliqué pour plusieurs orientations entre 0 et π , la précision angulaire dépendant du nombre N d'orientations testées.

Cette méthode d'estimation de l'orientation n'est pourtant pas à proprement parler un filtre orienté puisque cet opérateur ne se présente pas sous la forme d'une famille de masques de convolution.

Comme pour les approches de type gradient, cette méthode est fondée sur le modèle de géométrie différentielle selon lequel l'axe de plus faible variation des niveaux de gris est perpendiculaire à l'axe de plus forte variation. La réponse angulaire $R(\theta)$ dépend donc de l'attribut Q du réseau, évalué pour les angles θ et $\theta + \frac{\pi}{2}$:

$$R(\theta) = \frac{Q\left(\theta + \frac{\pi}{2}\right)}{Q(\theta) + \varepsilon} \quad (1.35)$$

La constante ε est proche de 0 et évite au dénominateur d'être nul. L'orientation recherchée correspond au maximum de $R(\theta)$.

Le paramètre Q évalue si, dans la direction θ , le voisinage autour du point étudié a une structure allongée. Cet attribut est calculé sur un réseau de lignes parallèles.

Ce réseau est développé de part et d'autre de points de départ, placés sur l'axe horizontal ou vertical, de part et d'autre du point central (Fig. 1.37).

La position des points de départ d_i est déterminée par l'angle θ que l'on souhaite étudier.

Ces points de départ seront placés sur l'axe vertical pour $\theta \in \left[-\frac{\pi}{4}, \frac{\pi}{4}\right]$ modulo π et sur l'axe horizontal pour $\theta \in \left[\frac{\pi}{4}, \frac{3\pi}{4}\right]$ modulo π .

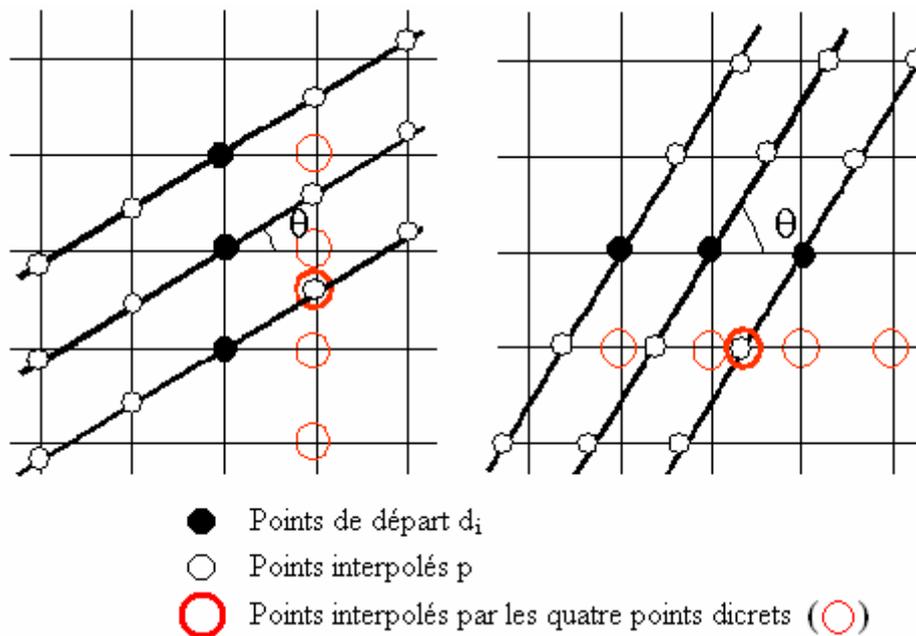


Fig. 1.37 Construction du Réseau Orienté de Lignes

Le réseau étant constitué de n_l lignes et de n_p points, l'attribut Q estime la somme des écarts quadratiques des intensités pour chaque ligne :

$$Q(\theta) = \sum_{i=1}^{n_l} \sum_{j=1}^{n_p} (d_i - p_{ij})^2 \quad (1.36)$$

Afin de réduire le coût calculatoire, les points interpolés p sont systématiquement placés sur un des axes de l'image, une interpolation 1-D suffit à estimer l'intensité lumineuse en ces points. L'interpolation utilisée est une interpolation polynomiale de degré 3.

Notons que cette réduction du coût calculatoire se fait au détriment de l'isotropie de la réponse du filtre, la distance séparant chaque ligne du réseau dépendant de l'orientation étudiée.

Le Réseau Orienté de Lignes, utilisant un tel modèle de géométrie différentielle, permet l'estimation d'une seule orientation locale.

Une variante de cet opérateur a été adaptée à l'estimation des orientations multiples dans [Mic 03]. La réponse angulaire est alors directement $R(\theta) = Q(\theta)$, ou un autre attribut similaire permettant d'identifier si le voisinage étudié présente une structure allongée.

Le modèle de géométrie différentielle est alors écarté au profit de la recherche du ou des axes de plus faible variation de l'image.

1.3.2.8 Bilan des approches filtres orientés

Par la détermination d'une réponse angulaire mettant en évidence les orientations locales, les filtres orientés permettent d'envisager l'estimation d'orientations multiples à l'échelle locale en chaque point de l'image.

La plupart de ces filtres, par leur construction en quadrature, permettent d'estimer l'orientation quelle que soit la phase locale de l'image.

Pour certaines de ces méthodes, le coût calculatoire est réduit grâce aux propriétés des filtres utilisés, qui permettent de reconstruire la réponse angulaire désirée à partir d'un nombre réduit de convolutions.

Nous avons également à notre disposition des filtres asymétriques, permettant d'évaluer les orientations modulo 2π .

Cependant la sélectivité angulaire de certains de ces filtres orientés n'est pas suffisante pour détecter en un même point plusieurs orientations proches.

Des exemples comparatifs de résultats de la mise en œuvre de ces filtres seront présentée au chapitre 2.

1.4 Conclusion

A travers une approche fondée sur la perception, nous avons tout d'abord dégagé les principales spécificités de l'orientation dans les images.

Nous avons étudié l'existence des orientations, leur variation dans l'image et l'influence de l'échelle d'analyse sur la perception des orientations. En particulier, dans les images présentant une orientation régulière, nous avons vu qu'il est possible de déterminer l'orientation à n'importe quelle échelle à partir des orientations locales.

Grâce à cette étude perceptuelle, nous avons proposé une définition formelle de l'orientation locale, que nous faisons correspondre aux tangentes aux lignes d'iso niveau.

Nous avons alors présenté diverses méthodes d'estimation de l'orientation et constaté que ces méthodes ne reposaient pas sur la même définition de l'orientation.

Les méthodes dérivatives cherchent la direction perpendiculaire à l'axe de plus grande variation linéaire ou quadratique du signal. En outre, ces opérateurs ne sont pas aptes à détecter plusieurs orientations en un même point.

Les méthodes utilisant des filtres orientés, fondées sur une recherche de pics d'énergie dans l'espace fréquentiel, permettent en théorie de pallier ce défaut. Nous constatons

néanmoins dans la pratique que les filtres utilisés ont soit une résolution angulaire limitée, soit un support de calcul trop grand. Ces inconvénients nous empêchent d'estimer à l'échelle locale des orientations multiples qui seraient angulairement proches.

Afin de caractériser au mieux les images étudiées, notre objectif est l'estimation en chaque point des orientations locales, éventuellement multiples.

Nous proposons donc par la suite une méthode d'estimation de ces orientations locales, fondée sur notre définition de l'orientation, et satisfaisant cet objectif.

Chapitre 2

Estimation des orientations locales par un réseau orienté.

2.1 Introduction

Dans le premier chapitre, nous avons proposé une définition de la notion d'orientations locales fondée sur les tangentes aux lignes d'iso niveau passant par le point considéré (définition 3). Nous avons également proposé une définition surfacique de la notion d'orientation (définition 4).

Nous introduisons dans ce chapitre une approche dédiée à l'estimation des orientations locales multiples s'appuyant sur cette dernière définition. Cette approche prend la forme d'un opérateur orientable utilisant un support de calcul de dimensions finies et satisfaisant aux objectifs suivants :

- une bonne sensibilité aux structures orientées : l'opérateur doit être capable de les détecter en tout point de l'image et, le cas échéant, d'en distinguer plusieurs en un même point ;
- un biais minimal dans l'estimation des orientations,
- une bonne immunité au bruit.

Notre opérateur doit également respecter certaines contraintes :

- l'estimation des orientations doit se faire sur un support de calcul de dimensions réduites afin de préserver le caractère local de l'orientation recherchée,
- le coût calculatoire doit rester aussi faible que possible.

Dans la première partie de ce chapitre, nous décrirons le principe de l'opérateur. Nous développerons alors la méthode de construction de cet opérateur et discuterons du choix des paramètres de construction.

Nous proposerons ensuite plusieurs stratégies d'implantation de cet opérateur.

Enfin nous étudierons, grâce à des simulations sur des images de synthèse, le comportement de l'opérateur et nous discuterons du réglage de ses différents paramètres.

Pour terminer, nous confronterons nos résultats à ceux obtenus par différents opérateurs présentés au chapitre 1.

2.2 Principe de l'opérateur

Soit I l'image étudiée dont les valeurs de niveaux de gris sont assimilables à une fonction $f(x, y)$. Soit $D(A, \theta)$ une fenêtre d'analyse centrée sur le point d'intérêt A , pour lequel au moins une orientation locale existe. En nous basant sur la définition 4, le voisinage du point A peut être assimilé à une image $\{1D\}$ de dimensionnalité intrinsèque 1 [Kri 96] dans chacune des directions présentes en ce point.

Ainsi, pour chacune des orientations locales, un tel voisinage peut être modélisé par une fonction profil développée dans la direction en question.

Soit h la fonction profil liée au modèle du voisinage, l'écart $\varepsilon_h(\theta)$ à ce modèle dans la direction θ est évalué selon la norme appropriée :

$$\varepsilon_h(\theta) = d(h(x.\sin(\theta) + y.\cos(\theta)), f(x, y))_{(x,y) \in D(A,\theta)} \quad (2.1)$$

En choisissant la norme L_n , nous obtenons par exemple :

$$\varepsilon_h(\theta) = \left(\iint_{D(A,\theta)} |h(x.\sin(\theta) + y.\cos(\theta)) - f(x, y)|^n .dx.dy \right)^{\frac{1}{n}} \quad (2.2)$$

Afin d'évaluer $\varepsilon_h(\theta)$, il convient de déterminer quel est le modèle de profil h le plus approprié à la direction à analyser.

Pour des commodités d'implantation discrète autorisant le calcul récursif, nous choisissons un domaine D de forme rectangulaire. La figure 2.1 présente la version symétrique de ce domaine par rapport au point A .

Ce support rectangulaire constitue un réseau de segments de droites sur lequel nous plaçons un repère formé par \vec{i} , l'axe longitudinal du réseau orienté dans la direction θ , et \vec{j} , l'axe qui lui est perpendiculaire. L'image I est donc ré-échantillonnée dans $D(A, \theta)$ en respectant le référentiel (\vec{i}, \vec{j})

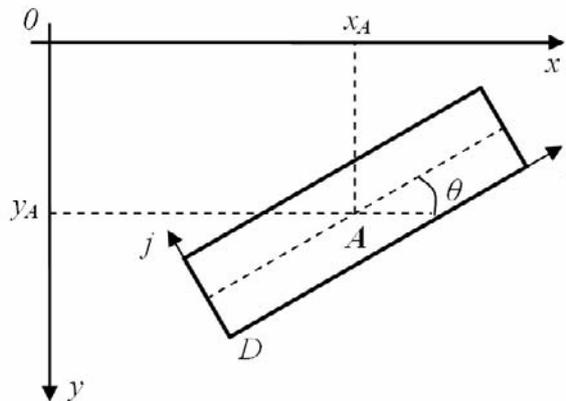


Fig. 2.1 Support D pour l'évaluation de l'écart au modèle au point A dans la direction θ

En utilisant ce support discret, le calcul de l'écart $\varepsilon_h(\theta)$ au modèle selon la norme L_n devient :

$$\varepsilon_h(\theta) = \left(\frac{1}{N_D} \sum_{(i,j) \in D} |h(j) - f(i,j)|^n \right)^{\frac{1}{n}} \quad (2.3)$$

avec N_D le nombre de points discrets dans le support D .

Le voisinage étudié correspond à une fonction profil h développée selon chacune des orientations de l'image. Pour le profil h correspondant le mieux au voisinage étudié, minimiser $\varepsilon_h(\theta)$ consiste à chercher les directions qui minimisent l'hétérogénéité des niveaux de gris le long de chaque ligne du réseau. Ceci équivaut à chercher les directions qui maximisent l'homogénéité des niveaux de gris le long de ces lignes.

Nous retenons cette deuxième possibilité pour faciliter la comparaison avec les autres méthodes de filtres orientés qui cherchent les directions maximisant un critère.

Sur ce principe, la construction d'un opérateur d'estimation des orientations locales dépend de plusieurs paramètres :

- l'attribut évaluant l'homogénéité le long des lignes,
- la symétrie du support : la construction symétrique ou asymétrique du réseau par rapport au point A étudié. L'évaluation de l'homogénéité se fera alors pour des directions comprises entre $-\pi/2$ et $\pi/2$ pour un réseau symétrique, et entre $-\pi$ et π pour un réseau asymétrique. Nous obtiendrons alors respectivement une estimation des orientations locales modulo π ou modulo 2π ;
- enfin la géométrie du support rectangulaire définissant le réseau de lignes. Cette géométrie dépend de deux paramètres : la taille, qui définit l'échelle d'analyse, et la forme, qui correspond à l'allongement du support et influe sur la sélectivité angulaire.

Ces différents paramètres permettent d'ajuster les performances de l'opérateur en terme de sensibilité aux orientations, de précision d'estimation, de sélectivité angulaire, d'immunité au bruit et nous permettent de contrôler l'échelle d'analyse.

2.3 Construction du réseau

2.3.1 Géométrie du réseau

2.3.1.1 Support rectangulaire du réseau

Nous introduisons deux types d'opérateurs orientés (symétrique et asymétrique) de forme rectangulaire, dont les dimensions sont la largeur D_L et la longueur D_R . Nous évaluons l'adéquation du modèle avec l'image sur ce support rectangulaire.

Nous considérons que l'échelle E d'analyse correspond au rayon du cercle couvert par le réseau lors de sa rotation. L'échelle E est exprimée en pixels (Fig. 2.2).

Nous pouvons noter que, pour une orientation θ donnée, la taille du support de calcul du réseau, égale à $D_L \times D_R$, est inférieure à la surface du cercle de rayon E .

Les relations entre les dimensions $D_L \times D_R$ du rectangle, l'échelle d'analyse E et la forme du réseau sont explicitées au paragraphe 2.3.4.2.

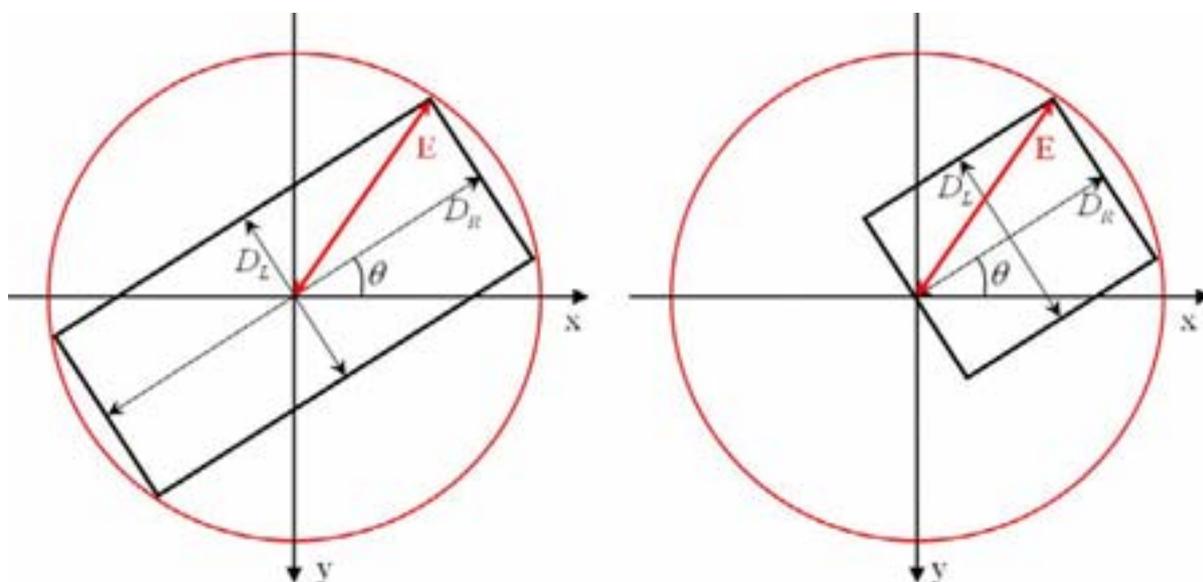


Fig. 2.2 Réseau symétrique et asymétrique pour une même échelle E

2.3.1.2 Réseau orienté

Pour construire le réseau orienté de lignes pour une orientation θ donnée, nous proposons de placer les lignes d'analyse à l'intérieur du support de calcul de dimensions $D_L \times D_R$. L'homogénéité est évaluée le long de ces segments de droite en des points régulièrement disposés sur les lignes.

Afin de garantir l'isotropie de notre réseau, l'espacement entre chacun des points d'analyse est choisi constant, et indépendant de l'orientation étudiée. Nous choisissons cet espacement égal à la distance entre chaque ligne. Les points d'analyse ainsi placés sur les lignes du réseau forment une grille régulière, de période identique à la grille des pixels.

Le réseau étant formé de L lignes et de p points par ligne, les dimensions D_L et D_R correspondantes sont $D_L = L$ et $D_R = p$.

Selon la symétrie choisie, le réseau se présente sous une forme différente par rapport au point central (Fig. 2.3 ou Fig. 2.4). Les réseaux présentés sur ces figures comptent chacun $L = 3$ lignes et $p = 5$ points par ligne.

Notons que les points du réseau ne correspondent généralement pas à des positions entières sur la grille des pixels. Les valeurs $v_{i,j,\theta}$ de niveau de gris des points du réseau doivent donc être déterminées grâce à une interpolation.

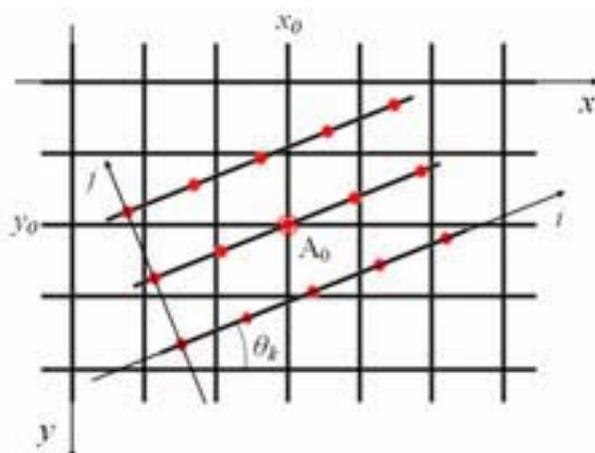


Fig. 2.3 Réseau symétrique

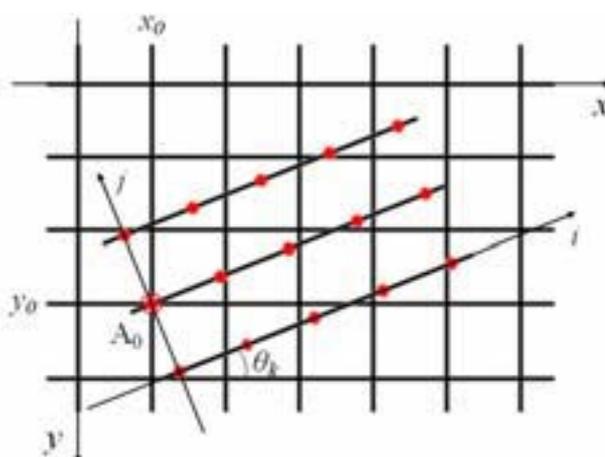


Fig. 2.4 Réseau asymétrique

2.3.2 Attribut d'homogénéité calculé le long du réseau

Conformément à la définition 4, nous cherchons les directions pour lesquelles le voisinage étudié correspond le plus au modèle recherché.

Nous présentons ici deux attributs correspondant à cet objectif. D'autres attributs correspondant à des configurations d'image particulières sont présentés au chapitre 3.

2.3.2.1 Attribut calculé le long des lignes

Le modèle d'une texture orientée étant un profil (1.2.2.3), estimer l'écart au modèle revient à estimer l'homogénéité des niveaux de gris le long des lignes du réseau.

Afin d'évaluer cette homogénéité, plusieurs possibilités sont envisageables. Dans ce qui suit, nous présentons deux estimateurs d'homogénéité H_1 et H_2 . Le premier s'inspire de la norme L_2 pour estimer l'écart $\varepsilon_h(\theta)$ au modèle, le deuxième se fonde sur une estimation du désordre, sans référence directe à un modèle.

D'autres choix sont bien sûr envisageables pour estimer l'homogénéité et donc l'écart au modèle. Il est également possible de combiner plusieurs mesures pour affiner l'estimation.

Variance des niveaux de gris

Afin d'évaluer $\varepsilon_h(\theta)$, nous devons déterminer quel est le modèle qui correspond le mieux au voisinage étudié. Le modèle étant un profil h développé dans une direction donnée, nous pouvons déterminer les valeurs $h(j)$ du profil indépendamment.

Pour chaque ligne j , la valeur du profil $h(j)$ qui minimise la somme des écarts quadratiques est la moyenne des niveaux de gris de la ligne.

Sur une image continue, l'écart quadratique moyen au modèle optimal pour la ligne j vaut :

$$\delta_{1j}(x, y, \theta) = \frac{1}{P} \int_{i=0}^P (v_{i,j,\theta} - \overline{v_{j,\theta}})^2 ds_{j,\theta} \quad (2.4)$$

Le couple (x, y) correspond aux coordonnées du point étudié dans l'image. Les points du réseau sont repérés par les coordonnées (i, j) dans le repère local du réseau, dépendant de l'angle θ (Fig. 2.3 et Fig. 2.4). Enfin, $\overline{v_{j,\theta}}$ représente le niveau de gris moyen de la ligne j .

Le calcul de cet attribut dans le domaine discret est réalisé par la moyenne quadratique des niveaux de gris des pixels rencontrés le long de chaque ligne. En considérant les valeurs des pixels le long des lignes comme les réalisations d'une variable aléatoire, nous assimilons cette mesure des écarts quadratique à l'estimation d'une variance.

L'attribut de variance des niveaux de gris le long de chaque ligne du réseau est donc défini par :

$$\Delta_{1j}(x, y, \theta) = \frac{1}{P} \sum_{i=1}^P \left(v_{i,j,\theta} - \frac{1}{P} \sum_{k=1}^P v_{k,j,\theta} \right)^2 \quad (2.5)$$

Afin de permettre par la suite une implantation récursive de cet attribut, nous le calculerons sous la forme (théorème de Koëning) :

$$\Delta_{1j}(x, y, \theta) = \frac{1}{P} \sum_{i=1}^P (v_{i,j,\theta})^2 - \left(\frac{1}{P} \sum_{i=1}^P v_{i,j,\theta} \right)^2 \quad (2.6)$$

Variationnelle des niveaux de gris

Notons que le critère d'homogénéité peut être évalué sans référence à un modèle de profil optimal.

Dans le cas d'appartenance locale à la classe $\{1|D\}$, lorsque l'orientation du réseau se confond avec l'orientation locale, chaque ligne du réseau est une ligne d'iso niveau.

Une mesure de l'adéquation à cette situation résulte donc de la mesure de la fluctuation des niveaux de gris observés le long de ces lignes.

La variationnelle est un bon indicateur de cette activité de fluctuation :

$$\delta_{2j}(x, y, \theta) = \int_{i=0}^P \left| \frac{\partial}{\partial s_{j,\theta}} v_{i,j,\theta} \right| ds_{j,\theta} \quad (2.7)$$

Dans le domaine discret, l'attribut variationnel le long d'une ligne est défini par la somme discrète des variations absolues de l'image le long de chaque ligne du réseau :

$$\Delta_{2_j}(x, y, \theta) = \sum_{i=1}^{p-1} |v_{i+1,j,\theta} - v_{i,j,\theta}| \quad (2.8)$$

L'homogénéité étant inversement proportionnelle au désordre, nous calculerons sur chaque ligne du réseau un attribut correspondant à l'inverse des attributs de variationnelle et de variance.

L'homogénéité calculée le long de chaque ligne du réseau est donc estimée par :

$$H_{1_j}(x, y, \theta) = \frac{1}{\varepsilon_0 + \Delta_{1_j}(x, y, \theta)} = \left(\varepsilon_0 + \frac{1}{p} \sum_{i=1}^p \left(v_{i,j,\theta} - \frac{1}{p} \sum_{k=1}^p v_{k,j,\theta} \right)^2 \right)^{-1} \quad (2.9)$$

et :

$$H_{2_j}(x, y, \theta) = \frac{1}{\varepsilon_0 + \Delta_{2_j}(x, y, \theta)} = \left(\varepsilon_0 + \sum_{i=1}^{p-1} |v_{i+1,j,\theta} - v_{i,j,\theta}| \right)^{-1} \quad (2.10)$$

La constante $\varepsilon_0 > 0$, $\varepsilon_0 \in \mathfrak{R}$ est proche de 0 et empêche le dénominateur de s'annuler.

2.3.2.2 Homogénéité calculée sur le réseau

Une fois l'attribut d'homogénéité évalué pour chaque ligne, nous devons combiner les différentes valeurs obtenues afin d'obtenir l'homogénéité $H(\theta)$ du réseau au point étudié.

Les valeurs de chaque ligne sont pondérées par une fonction ω .

L'homogénéité $H(\theta)$, correspondant à la réponse angulaire $R(\theta)$ du réseau, est donc :

$$H_1(x, y, \theta) = \sum_{j=1}^L \omega(j) H_{1_j}(x, y, \theta) \quad (2.11)$$

ou :

$$H_2(x, y, \theta) = \sum_{j=1}^L \omega(j) H_{2_j}(x, y, \theta) \quad (2.12)$$

Afin de respecter l'isotropie du réseau, la fonction de pondération ω doit être symétrique par rapport à la ligne centrale du réseau.

Cette fonction ω , qui correspond à une fonction d'apodisation du réseau, a très peu d'influence sur l'estimation de l'orientation. En effet modifier ω équivaut généralement à modifier la dimension D_L du réseau. Par conséquent, nous prendrons comme fonction de pondération la fonction constante unitaire $\omega(j) = 1$.

2.3.2.3 Calcul théorique de la réponse angulaire sur un profil sinusoïdal

Afin de mieux connaître son comportement, nous calculons la réponse angulaire théorique de l'opérateur sur une image continue.

Nous prendrons ici le cas correspondant à une image I , de valeurs $f(x, y)$, générée par une fonction profil h sinusoïdale.

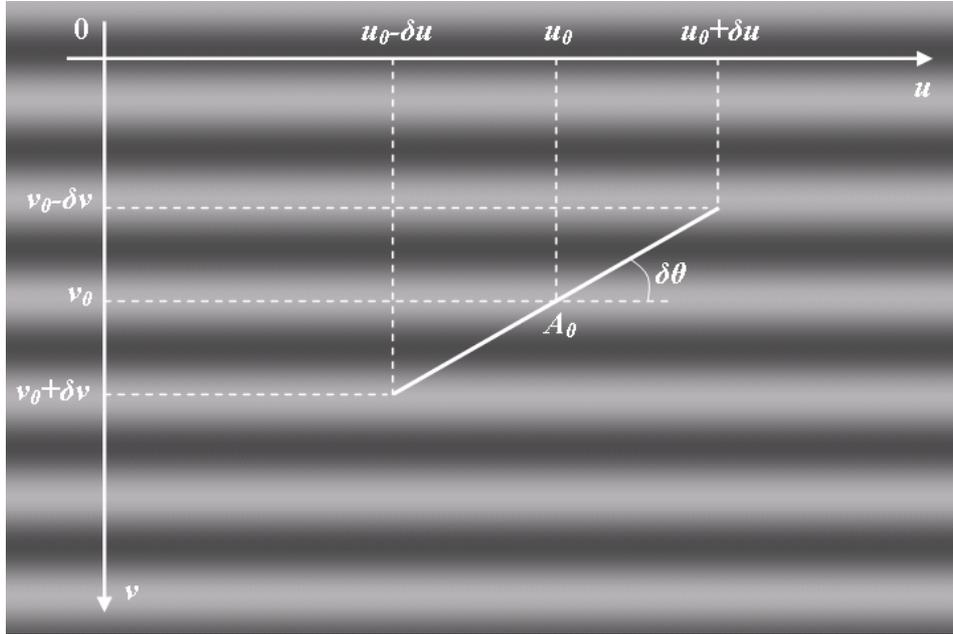


Fig. 2.5 Calcul théorique de la réponse angulaire

Nous nous plaçons dans le repère (O, \vec{u}, \vec{v}) dont l'axe \vec{u} est dans la direction de la texture. L'intensité de l'image en un point (u, v) ne dépend donc que de l'abscisse v de ce point :

$$f(u, v) = h(v) = A \cdot \cos\left(\frac{2\pi}{T} v\right) + B \quad (2.13)$$

Nous calculons, en un point $A_0(u_0, v_0)$, la valeur de la variance des niveaux de gris, puis de la variationnelle des niveaux de gris, le long d'une ligne du réseau de longueur D_R et orientée d'une différence d'angle $\delta\theta$ par rapport à la direction de la texture.

Variance

Dans le cas continu, la variance des niveaux de gris s'exprime par :

$$\delta_{i,j}(u_0, v_0, \delta\theta) = \frac{1}{D_R} \int_{D_R} (f(u, v) - \overline{f_{\delta\theta}})^2 ds_{\delta\theta} \quad (2.14)$$

avec $\overline{f_{\delta\theta}}$ qui représente la moyenne d'intensité de l'image le long de la ligne du réseau étudiée :

$$\overline{f_{\delta\theta}} = \frac{1}{D_R} \int_{D_R} f(u, v) ds_{\delta\theta} \quad (2.15)$$

La grandeur $s_{\delta\theta}$ représente l'abscisse le long de la ligne du réseau étudiée.

Dans le cas de la fonction profil sinusoidale, cette moyenne vaut :

$$\begin{aligned}\overline{f_{\delta\theta}} &= \frac{1}{2\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} h(\nu) d\nu = B + \frac{A}{2\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} \cos\left(\frac{2\pi}{T}\nu\right) d\nu \\ \overline{f_{\delta\theta}} &= B + \frac{A.T}{4\pi\delta\nu} \left[\sin\left(\frac{2\pi}{T}(\nu_0 + \delta\nu)\right) - \sin\left(\frac{2\pi}{T}(\nu_0 - \delta\nu)\right) \right]\end{aligned}\quad (2.16)$$

Ce qui conduit à :

$$\delta_{1j}(u_0, \nu_0, \delta\theta) = \frac{1}{2\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} (h(\nu) - \overline{f_{\delta\theta}})^2 d\nu = \frac{1}{2\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} \left(A \cdot \cos\left(\frac{2\pi}{T}\nu\right) + B - \overline{f_{\delta\theta}} \right)^2 d\nu \quad (2.17)$$

$$\delta_{1j}(u_0, \nu_0, \delta\theta) = \frac{A^2}{2} + (B - \overline{f_{\delta\theta}})^2 + \frac{A^2}{4\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} \cos\left(\frac{4\pi}{T}\nu\right) d\nu + \frac{A(B - \overline{f_{\delta\theta}})}{\delta\nu} \int_{\nu=v_0-\delta\nu}^{\nu_0+\delta\nu} \cos\left(\frac{2\pi}{T}\nu\right) d\nu \quad (2.18)$$

Lorsque $\delta\nu$ devient grand par rapport à T , c'est-à-dire lorsque $\delta\theta$ est grand et que la longueur D_R du réseau est suffisamment grande devant la période T , alors nous obtenons une valeur quasi-constante pour la variance : $\delta_{1j}(u_0, \nu_0, \delta\theta) \approx \frac{A^2}{2}$.

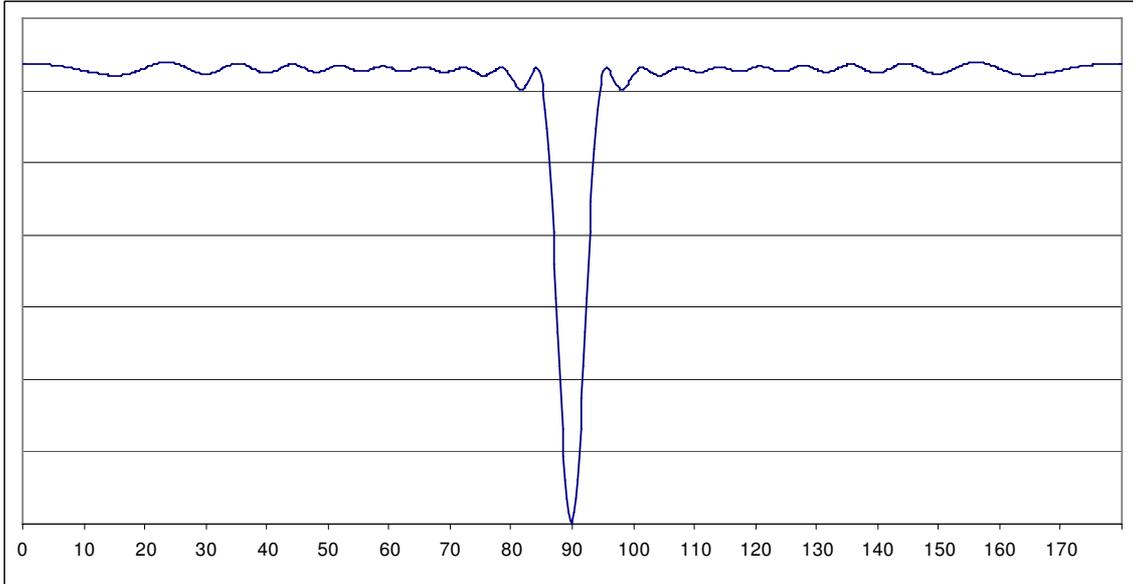


Fig. 2.6 Ecart quadratique au modèle, calculé sur une image de profil sinusoidal, en fonction de θ

Les principales caractéristiques de la variance sont la rapidité de variation de la réponse angulaire autour de l'orientation recherchée et les faibles variations de cette réponse autour d'une valeur constante lorsque l'on s'éloigne de l'orientation recherchée (Fig. 2.6).

Les particularités de cet attribut confèrent à notre réseau la capacité d'estimer précisément l'orientation malgré la présence de bruit.

Variationnelle

Dans le cas continu, la variationnelle des niveaux de gris s'écrit sous la forme :

$$\delta_{2j}(u_0, v_0, \delta\theta) = \int_{D_R} \left| \frac{\partial}{\partial s_{\delta\theta}} f(u, v) \right| ds_{\delta\theta} \quad (2.19)$$

avec $s_{\delta\theta}$ représentant l'abscisse curviligne le long de la ligne du réseau étudiée.

Comme $f(u, v) = h(v)$, cela revient à :

$$\delta_{2j}(u_0, v_0, \delta\theta) = \int_{v=v_0-\delta v}^{v_0+\delta v} \left| \frac{\partial}{\partial v} h(v) \right| dv \quad (2.20)$$

avec $\delta v = D_R \cdot \sin(\delta\theta)$

Si h est monotone et dérivable sur l'intervalle $[v_0 - \delta v, v_0 + \delta v]$, alors nous obtenons :

$$\delta_{2j}(u_0, v_0, \delta\theta) = |h(v_0 + \delta v) - h(v_0 - \delta v)| \quad (2.21)$$

Si $\delta v = k.T + \alpha$ avec $0 \leq \alpha < T$, $\alpha \in \mathfrak{R}^+$ et $k \in \mathbb{Z}^+$

$$\delta_{2j}(u_0, v_0, \delta\theta) = 2k \int_{v=0}^T \left| \frac{\partial}{\partial v} h(v) \right| dv + \int_{v=v_0-\alpha}^{v_0+\alpha} \left| \frac{\partial}{\partial v} h(v) \right| dv \quad (2.22)$$

Pour $h(v) = A \cdot \cos\left(\frac{2\pi}{T}v\right) + B$, il vient :

$$\delta_{2j}(u_0, v_0, \delta\theta) = 4kA + \int_{v=v_0-\alpha}^{v_0+\alpha} \left| \frac{\partial}{\partial v} h(v) \right| dv \quad (2.23)$$

Nous pouvons ensuite évaluer $\int_{v=v_0-\alpha}^{v_0+\alpha} \left| \frac{\partial}{\partial v} h(v) \right| dv$ en décomposant la fonction h en parties monotones dans l'intervalle $[v_0 - \alpha, v_0 + \alpha]$ et en utilisant la relation (2.21).

Dans le cas où notre réseau a une dimension D_R très supérieure à la période T du profil sinusoïdal, le terme $\int_{v=v_0-\alpha}^{v_0+\alpha} \left| \frac{\partial}{\partial v} h(v) \right| dv$ devient négligeable devant $4kA$. Nous trouvons alors que la variationnelle est proportionnelle à la longueur δv , autrement dit que $\delta_{2j}(u_0, v_0, \delta\theta) \propto \sin(\delta\theta)$.

La principale caractéristique de cet attribut variationnel est de continuer à croître lorsque l'on s'éloigne de la direction recherchée (Fig. 2.7).

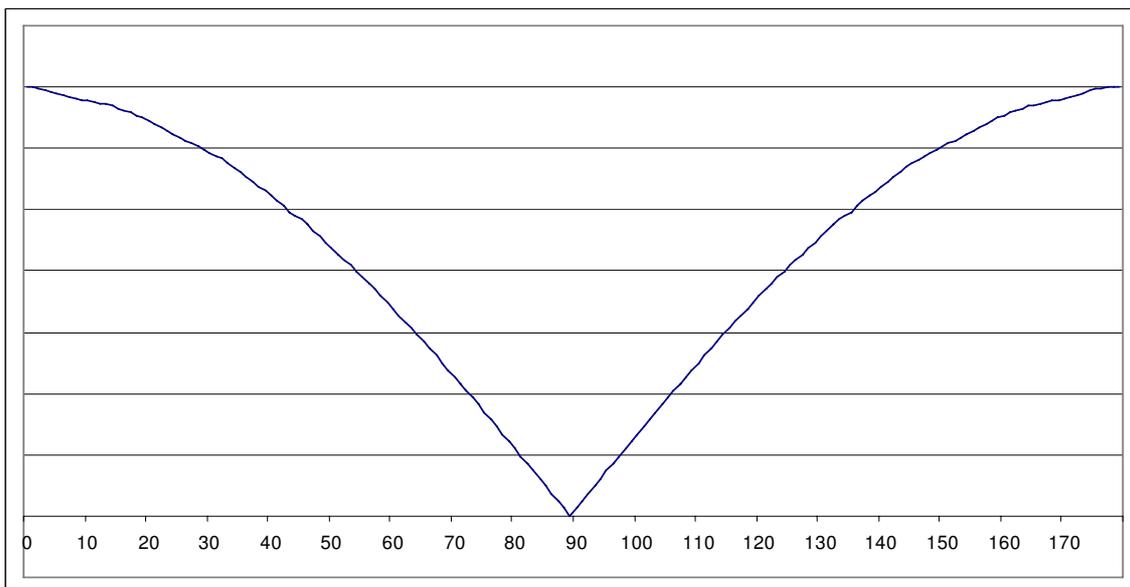


Fig. 2.7 Variationnelle calculée sur une image de profil sinusoïdal, en fonction de θ

La pente de réponse angulaire autour de l'orientation recherchée est quasiment linéaire. Cela rend la convergence vers le mode recherché plus lente, et cela peut conduire à une estimation moins précise de l'orientation.

Cependant ce phénomène augmente nos chances de détecter l'orientation de la texture si le pas angulaire choisi est grand et que l'orientation recherchée ne correspond pas à une valeur testée par le réseau.

Etude de l'influence du bruit sur les réponses

Dans le cas où notre image précédente est bruitée par un bruit blanc gaussien de variance σ_B^2 , nous pouvons déterminer quel sera le comportement des deux attributs calculés sur le réseau.

Le minimum de la courbe, correspondant à l'orientation recherchée, s'éloigne de la valeur idéale nulle.

Cette variation est quantifiable et, pour un réseau de L lignes avec p points par ligne, elle vaut $\frac{2\sigma_B}{\sqrt{\pi}} \cdot L \cdot (p - 1)$ pour l'attribut fondé sur la variationnelle (calcul disponible en Annexe F) et $L \cdot \sigma_B^2$ pour l'attribut fondé sur la variance.

Ce résultat est vérifié par l'expérimentation (Fig. 2.8). Sur le tracé, les courbes de la variationnelle et de la variance ont été ramenées à la même échelle.

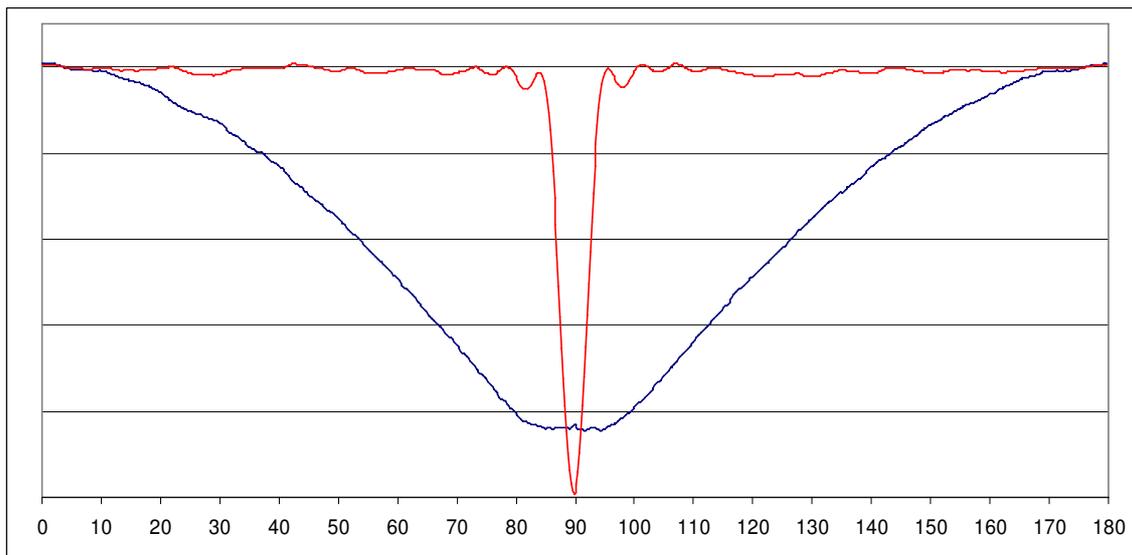


Fig. 2.8 Variance et variationnelle en fonction de θ sur une image de profil sinusoidal en présence de bruit

La valeur minimale de la réponse angulaire de l'attribut fondé sur la variationnelle est davantage perturbée par le bruit que l'attribut fondé sur la variance. Ceci est dû à la combinaison d'une forte sensibilité au bruit de la différence finie utilisée dans le calcul de la variationnelle et d'une réponse variant plus lentement que celle de la variance autour du minimum recherché. Le pic résultant est donc plus large, conduisant potentiellement à une estimation imprécise de l'orientation.

Dans le cas où une seule orientation est présente en chaque point d'une image bruitée, une Analyse en Composantes Principales de la réponse angulaire (Annexe D) de l'opérateur permet d'estimer plus précisément l'orientation de l'image, en particulier si l'attribut fondé sur la variationnelle est utilisé.

2.3.3 Confiance de l'estimation

Nous souhaitons associer à la mesure de l'orientation une confiance relative à cette estimation.

La valeur de confiance de notre estimation est étroitement corrélée avec la valeur d'homogénéité optimale correspondant à la direction estimée.

Dans le cas général, nous associons à une orientation θ_0 estimée par notre opérateur une confiance normalisée absolue $C_A(\theta_0)$ définie par :

$$C_A(\theta_0) = \frac{H(\theta_0) - H_{\min}}{H(\theta_0)} \quad (2.24)$$

La grandeur H_{\min} représente le minimum d'homogénéité calculable sur le réseau. H_{\min} dépend à la fois des dimensions du réseau, de l'attribut d'homogénéité calculé sur le réseau et des extrema des niveaux de gris de l'image.

Dans le cas où une seule orientation est présente en chaque point de l'image étudiée, nous pouvons également utiliser l'expression de la confiance telle qu'elle a été décrite dans [LeP 03] :

$$C_R(\theta_0) = \frac{H(\theta_0) - H(\theta_0 + \pi/2)}{H(\theta_0)} \quad (2.25)$$

Cette confiance relative C_R fait apparaître le rapport entre l'homogénéité dans la direction de l'orientation estimée et l'homogénéité dans la direction perpendiculaire : cette homogénéité C_R est d'autant plus grande que la différence entre ces deux homogénéités est importante. Si une seule orientation est présente au point étudié, l'homogénéité $H(\theta_0 + \pi/2)$ est dans la plupart des cas le minimum de la réponse angulaire au point étudié.

Nous ne pouvons pas utiliser cette confiance si plusieurs orientations cohabitent au même point car il n'y a alors aucune relation prédéfinie entre l'homogénéité dans la direction estimée et dans sa direction perpendiculaire.

2.3.4 Paramètres du réseau

2.3.4.1 Echelle et forme du réseau

Notre réseau est constitué de plusieurs segments de droites de longueurs identiques le long desquels nous évaluons un attribut d'homogénéité.

Or, une fois la symétrie et l'échelle d'analyse E du réseau déterminées, les dimensions D_L et D_R du réseau ne sont plus indépendantes. Elles sont en fait liées par un paramètre relatif à la forme du réseau.

Cette forme est quantifiée par un facteur de forme F , défini par :

$$F = \frac{D_L}{D_R} \quad (2.26)$$

Nous rappelons que D_R représente la longueur radiale de notre réseau et D_L en représente la largeur.

Puisque nous souhaitons estimer l'homogénéité radiale autour du point d'analyse, la largeur D_L du réseau sera toujours inférieure ou égale à la longueur D_R . La largeur minimale $D_L = 1$ correspond à un réseau constitué d'une seule ligne d'analyse.

Le facteur de forme F pourra donc prendre des valeurs comprises dans l'intervalle $\left[\frac{1}{2E}, 1\right]$ dans le cas symétrique, et dans l'intervalle $\left[\frac{1}{E}, 1\right]$ dans le cas asymétrique. Le cas

minimal correspond à un réseau constitué d'une seule ligne, et le cas $F = 1$ correspond à un réseau carré

Toute la géométrie du réseau se résume donc à deux paramètres : l'échelle d'analyse E et le facteur de forme F .

2.3.4.2 Relations entre les paramètres géométriques du réseau

Une fois l'échelle d'analyse E et le facteur de forme F choisis, il est possible d'en déduire la largeur D_L et la longueur radiale D_R du réseau correspondant (Fig. 2.2).

Dans le cas symétrique, la relation entre l'échelle d'analyse E , la largeur D_L et la longueur D_R s'exprime sous la forme :

$$E = \frac{1}{2} \sqrt{D_L^2 + D_R^2} \quad (2.27)$$

Nous déduisons donc D_L et D_R de E et F par :

$$\left\{ \begin{array}{l} D_L = \frac{2E}{\sqrt{1 + \frac{1}{F^2}}} \\ D_R = \frac{2E}{F \sqrt{1 + \frac{1}{F^2}}} \end{array} \right. \quad (2.28)$$

Dans le cas asymétrique, la relation entre E , D_L et D_R est la suivante :

$$E = \frac{1}{2} \sqrt{D_L^2 + 4D_R^2} \quad (2.29)$$

Nous déduisons alors D_L et D_R de E et F par :

$$\left\{ \begin{array}{l} D_L = \frac{E}{\sqrt{\frac{1}{4} + \frac{1}{F^2}}} \\ D_R = \frac{E}{F \sqrt{\frac{1}{4} + \frac{1}{F^2}}} \end{array} \right. \quad (2.30)$$

En reprenant les exemples de la figure Fig. 2.2, voyons quels sont les paramètres E et F . Pour ces deux réseaux, le facteur de forme est $F = \frac{3}{5}$. L'échelle d'analyse est $E = \frac{1}{2} \sqrt{34}$

(soit environ $E \approx 2.92$) pour le réseau symétrique et $E = \frac{1}{2}\sqrt{109}$ (soit $E \approx 5.22$) pour le réseau asymétrique.

2.3.4.3 Echantillonnage des orientations

Pour estimer les orientations, nous évaluons l'homogénéité angulaire locale $H(\theta)$ autour du point étudié. Or, nous ne pouvons pas évaluer cette homogénéité sur tout le continuum des orientations. Nous la déterminerons donc pour un nombre fini N d'angles θ_k , répartis sur la plage angulaire que l'on souhaite étudier. Nous obtenons ainsi un échantillonnage $H(\theta_k)$ de l'homogénéité angulaire.

Le pas d'échantillonnage T_θ entre chacune des valeurs testées doit être suffisamment faible pour permettre de distinguer plusieurs orientations proches. En effet, si notre opérateur est capable de séparer et d'estimer en un point deux orientations séparées d'un angle φ , alors nous devons prendre $T_\theta \leq \varphi/2$ afin de respecter la condition d'échantillonnage de Shannon.

L'échantillonnage ainsi effectué sur la réponse angulaire correspond également à une quantification des orientations estimées. Il convient donc de choisir également T_θ inférieur à la résolution angulaire fixée par l'utilisateur.

Notons que, dans le cas symétrique nous avons la relation $N = N_S = \pi/T_\theta$, et dans le cas asymétrique $N = N_A = 2\pi/T_\theta$.

2.3.4.4 Choix des paramètres

Ainsi pour déterminer l'ensemble de la géométrie du réseau, il suffit à l'utilisateur de choisir l'échelle d'analyse E , le facteur de forme F et le pas d'échantillonnage de la réponse angulaire T_θ .

Les paramètres E et F permettent de déterminer les dimensions D_L et D_R de notre réseau. Afin d'assurer l'isotropie de la mesure, nous constatons qu'il convient de choisir un nombre de lignes L impair, et également, pour le cas du réseau symétrique, un nombre de points par ligne p impair.

Dans la pratique, nous déterminerons le couple $\{L, p\} \in \mathbb{N}^2$ correspondant au mieux aux paramètres E et F choisis, et dont les éléments respectent les conditions de parité précédentes.

En ce qui concerne le pas d'échantillonnage T_θ , il influe linéairement sur le coût calculatoire de l'estimation. Le compromis entre la résolution angulaire et le coût calculatoire devra donc être choisi selon l'application envisagée.

Nous verrons au paragraphe suivant l'influence de ces paramètres sur l'estimation de l'orientation.

2.4 Implantation du réseau

2.4.1 Détermination des niveaux de gris le long des lignes

Comme déjà dit, les positions des points du réseau ne correspondant en général pas à des valeurs entières sur la grille des pixels. Il est donc nécessaire de déterminer les valeurs $v_{i,j,\theta}$ d'intensité de l'image en ces points du réseau.

2.4.1.1 Interpolation 2-D

L'interpolation choisie doit déterminer les valeurs $v_{i,j,\theta}$ de niveau de gris des points du réseau. Ces points ne sont a priori sur aucun des axes de la grille des pixels de l'image (contrairement au Réseau Orienté de Lignes, introduit par [LeP 01]). Pour déterminer directement ces valeurs, nous devons donc utiliser une interpolation 2-D.

Pour une image I assimilable à une fonction f , l'interpolation permet d'estimer les valeurs de $f(x, y), (x, y) \in \mathfrak{R}^2$, à partir de ses échantillons $f(i, j), (i, j) \in N^2$. D'une manière générale, le processus d'interpolation 2-D peut être décrit comme la convolution de l'image et de la réponse impulsionnelle d'un filtre de reconstruction continu r :

$$f(x, y) = \sum_i \sum_j f(i, j) \cdot r(x - i, y - j) \quad (2.31)$$

L'interpolation 2-D peut être séparée en x et y en un produit de plusieurs interpolations 1-D [Thé 00]. La complexité calculatoire est ainsi diminuée, d'un facteur dépendant de la complexité initiale de l'interpolation.

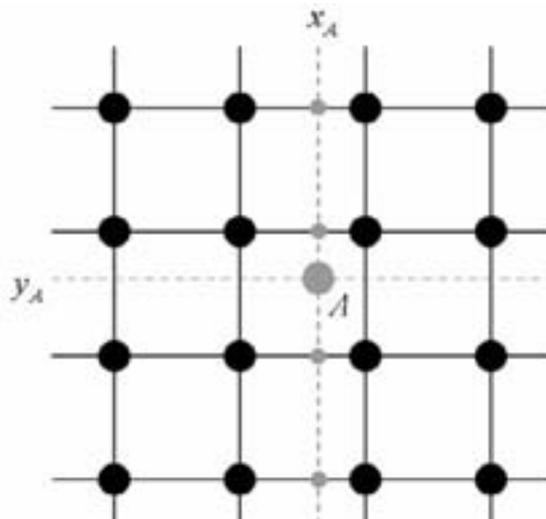


Fig. 2.9 Combinaison d'interpolations 1-D pour effectuer une interpolation 2-D

La figure 2.9 présente l'estimation par interpolation du point A par cette méthode. Tout d'abord les valeurs des points intermédiaires d'abscisses x_A sont déterminées par quatre interpolations 1-D sur les axes horizontaux. Ces valeurs sont ensuite utilisées pour une interpolation 1-D verticale déterminant la valeur recherchée aux coordonnées (x_A, y_A)

2.4.1.2 Méthodes d'interpolation

L'interpolation utilisée doit être de qualité suffisante pour permettre de reconstruire la structure locale de l'image malgré la présence éventuelle de bruit. La qualité d'interpolation est d'autant plus importante que nous évaluons un critère d'homogénéité de l'image. L'interpolation utilisée ne doit pas lisser l'image. Elle ne doit pas non plus l'entacher de perturbations.

Nous exposons maintenant les différents filtres de reconstruction qui sont susceptibles d'être utilisés dans le cadre de notre estimation de l'orientation, afin de sélectionner celui qui correspond le mieux aux précédents critères.

Interpolation idéale

Si l'échantillonnage de l'image I respecte la condition de Shannon, alors l'image originale continue peut être reconstruite à partir de ses échantillons. Le filtre idéal de reconstruction correspondant est un filtre passe-bas de fréquence de coupure $f_c = f_e / 2$, avec f_e représentant la fréquence d'échantillonnage. Le filtre de convolution correspondant est la fonction sinus cardinal :

$$r_{\text{idéal}}(x) = \frac{\sin(\pi x)}{\pi x} = \text{sinc}(x) \quad (2.32)$$

La fonction sinus cardinal n'a pas un support fini et par conséquent son utilisation directe pour l'interpolation d'un point requiert la convolution du filtre sur l'intégralité de l'image. Cette convolution étant trop coûteuse en temps de calcul nous pouvons néanmoins utiliser des versions fenêtrées de ce filtre de reconstruction.

Interpolation sinus cardinal fenêtré

En fenêtrant la fonction de reconstruction idéale sinus cardinal, on obtient un filtre de reconstruction à réponse impulsionnelle finie :

$$r_{\text{sinc}}(x) = \text{sinc}(x) \cdot w(x), \quad w(x) = 0 \text{ si } |x| \geq l_r \quad (2.33)$$

Un tel filtre d'interpolation présente toutefois un rapport performances sur coût calculatoire très faible [Uns 02] et ne convient donc pas à notre méthode, demandant à la fois une interpolation suffisamment précise et peu coûteuse.

Interpolation polynomiale

Nous pouvons néanmoins approximer le filtre de reconstruction idéal par un polynôme à support compact.

Les fonctions d'interpolation polynomiale de plus faible degré, comme l'interpolation au plus proche voisin ou l'interpolation linéaire sont loin de permettre de reconstruire correctement le signal, tout particulièrement si celui-ci ne présente pas exclusivement des variations lentes. En effet, avec de telles méthodes, les composantes hautes fréquences de l'image sont particulièrement atténuées.

Afin d'obtenir des résultats plus satisfaisants, nous pouvons utiliser une interpolation polynomiale de degré 3, utilisant 4 points pour déterminer la valeur à interpoler.

La méthode choisie est l'interpolation cubique de Keys :

$$r_{\text{Keys}}(x) = \begin{cases} (a+2)|x|^3 - (a+3)|x|^2 + 1 & \text{si } |x| < 1 \\ a|x|^3 - 5a|x|^2 + 8a|x| - 4a & \text{si } 1 \leq |x| < 2 \\ 0 & \text{si } 2 \leq |x| \end{cases} \quad (2.34)$$

La valeur du paramètre a est $a = -0.5$. C'est pour cette valeur que les trois premiers termes du développement en série de Taylor de la fonction interpolée correspondent à ceux du développement du signal original [Key 81]. Cette valeur assure la meilleure qualité d'interpolation pour cette interpolation cubique [Uns 02].

Interpolation généralisée : splines

Il est possible d'utiliser les B-splines pour fournir une représentation continue d'un signal discret, et peuvent donc permettre la reconstruction du signal par interpolation [Uns 91] [Uns 99].

Une spline polynomiale de degré n est une fonction polynomiale par morceaux de degré n , qui est continue et dont les dérivées sont continues jusqu'à l'ordre $(n-1)$.

Une spline est caractérisée de manière unique par son développement en B-splines :

$$s(x) = \sum_{k \in \mathbb{Z}} c(k) \beta^n(x-k) \quad (2.35),$$

pour lequel β^n est la B-spline centrale de degré n , et $c(k)$ les coefficients des B-splines.

Une B-spline de degré n se construit par les $(n+1)$ convolutions d'une fonction β^0 rectangulaire symétrique centrée :

$$\beta^0(x) = \begin{cases} 1 & \text{si } -\frac{1}{2} < x < \frac{1}{2} \\ \frac{1}{2} & \text{si } |x| = \frac{1}{2} \\ 0 & \text{sinon} \end{cases} \quad (2.36)$$

$$\beta^n(x) = \underbrace{(\beta^0 * \beta^0 * \dots * \beta^0)}_{(n+1)\text{ fois}}(x) \quad (2.37)$$

Nous pouvons également obtenir une expression directe de la B-spline de degré n [Uns 99] :

$$\beta^n(x) = \frac{1}{n!} \sum_{k=0}^{n+1} C_{n+1}^k (-1)^k \left(x - k + \frac{n+1}{2}\right)_+^n \text{ avec } (x)_+^n = \begin{cases} x^n & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (2.38)$$

Afin de pouvoir reconstruire le signal original $f(x)$ à partir de ses échantillons $f(k)$, il faut déterminer sa représentation à partir de B-splines. Il faut en particulier déterminer les coefficients $c(k)$ de manière à ce que la représentation du signal corresponde exactement au signal aux points d'échantillonnage. Cette détermination des coefficients $c(k)$, qui peut se faire par résolution d'un système d'équations [Leh 99], s'effectue plus rapidement par filtrage numérique [Uns 99].

L'interpolation ainsi effectuée est dite généralisée car la fonction de reconstruction β^n n'a pas pour coefficients les échantillons du signal mais une transformation de ceux-ci [Thé 00].

En utilisant une B-spline de degré 3 avec les coefficients $c(k)$ déterminés par filtrage discret récursif, nous obtenons une meilleure qualité d'interpolation que l'interpolation cubique de Keys, pour un temps de calcul comparable [Leh 99][Uns 02]. L'expression de cette B-spline est :

$$\beta^3(x) = \begin{cases} \frac{2}{3} - |x|^2 + \frac{|x|^3}{2} & \text{si } 0 \leq |x| < 1 \\ \frac{(2 - |x|)^3}{6} & \text{si } 1 \leq |x| < 2 \\ 0 & \text{si } 2 \leq |x| \end{cases} \quad (2.39)$$

2.4.2 Implantation rapide du réseau

2.4.2.1 Stratégies d'implantation rapide

Pour calculer l'homogénéité angulaire $H(\theta_k)$ en un seul point (x_0, y_0) de l'image nous procédons directement au calcul des niveaux de gris $v_{i,j,\theta}$ à l'aide d'une des interpolations décrites ci-dessus.

Par contre, lorsque nous souhaitons obtenir cette réponse angulaire pour tous les points de l'image, calculer une interpolation 2-D pour chaque point du réseau, pour chaque orientation testée et en chaque point de l'image serait trop coûteux en temps de calcul, même en utilisant le produit d'interpolations 1-D présenté en 2.4.1.1. Nous devons par conséquent envisager une technique d'implantation rapide de notre méthode.

Nous pouvons tout d'abord envisager de ne pas utiliser d'interpolation, et de se restreindre aux orientations pour lesquelles certains points de la grille correspondent à l'orientation étudiée. Ce principe est utilisé par exemple dans la transformée de Radon discrète [Gue 02]. Avec cette méthode, le nombre d'orientations que l'on peut étudier augmente avec la taille du

support utilisé. Comme nous souhaitons estimer l'orientation à petite échelle avec une bonne précision angulaire, nous ne pouvons retenir cette méthode pour implanter notre algorithme.

Nous pouvons envisager également de réduire le temps de calcul nécessaire aux interpolations. Nous proposons une telle méthode, utilisant des rotations de l'image, qui permet de plus un calcul récursif de notre attribut d'homogénéité.

2.4.2.2 Utilisation de rotations de l'image

Nous proposons ici une méthode pour évaluer rapidement la réponse angulaire $R(\theta_k) = H(\theta_k)$ de notre réseau. Cette méthode consiste à utiliser des rotations de l'image pour réduire le nombre d'interpolations nécessaires.

Pour chaque orientation testée θ_k , au lieu de calculer pour chaque point de l'image I les valeurs de niveau de gris interpolées des points du réseau correspondant, nous effectuons une rotation de l'image d'angle $-\theta_k$. Une fois cette rotation effectuée, les pixels de l'image correspondent aux points du réseau. Nous pouvons alors évaluer l'attribut de notre réseau directement sur toute l'image.

La figure 2.10 illustre l'équivalence entre l'application d'un réseau d'angle θ_k sur l'image originale I et l'utilisation d'un réseau horizontal sur l'image $I_{-\theta_k}$ ayant subi une rotation d'angle $-\theta_k$. Sur cette figure $\theta_k = -\pi/4$.

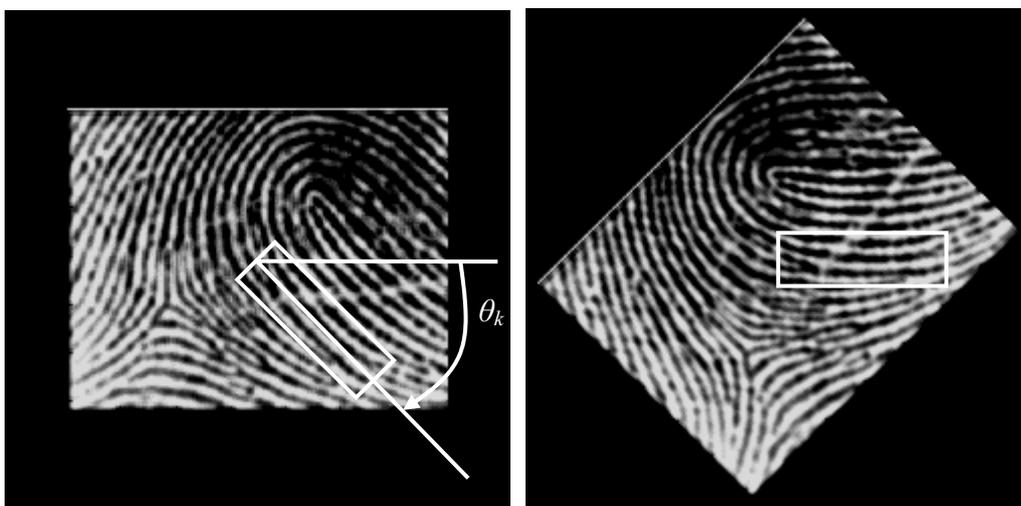


Fig. 2.10 Application d'un réseau horizontal sur la rotation d'une image

2.4.2.3 Rotation inverse des résultats

Excepté pour des valeurs d'angles de rotation $\theta_k = 0$ modulo $\pi/2$, la grille des pixels de l'image tournée $I_{-\theta_k}$ ne correspond pas à la grille des pixels de l'image I de départ. Ainsi, pour la direction θ_k , les valeurs d'homogénéité sont donc évaluées pour des positions différentes de celles initialement recherchées.

Pour pallier cet inconvénient, nous effectuons une rotation inverse d'angle θ_k des résultats.

Puisque nous effectuons deux rotations pour chaque angle θ_k , une de l'image et l'autre de l'homogénéité évaluée sur l'image dans cette direction, il est essentiel que la méthode de rotation soit de bonne qualité.

2.4.2.4 Rotation rapide en trois passes

La rotation d'une image est décrite par la matrice de transformation M_R :

$$M_R = \begin{bmatrix} \cos(\theta_k) & \sin(\theta_k) \\ -\sin(\theta_k) & \cos(\theta_k) \end{bmatrix} \quad (2.40)$$

Notons que cette matrice diffère ici de la matrice communément admise pour la rotation, ceci étant dû à l'orientation vers le bas de l'axe Y de l'image.

Afin d'effectuer des rotations rapides de l'image I , nous utilisons la méthode de rotation en trois passes présentée dans [Uns 95][Owe 96].

Cette méthode se base sur la décomposition de la matrice de rotation M_R en trois matrices M_{1x} , M_{2y} et M_{3x} :

$$M_R = M_{1x} \times M_{2y} \times M_{3x} = \begin{bmatrix} 1 & \tan\left(\frac{\theta_k}{2}\right) \\ 0 & 1 \end{bmatrix} \times \begin{bmatrix} 1 & 0 \\ -\sin(\theta_k) & 1 \end{bmatrix} \times \begin{bmatrix} 1 & \tan\left(\frac{\theta_k}{2}\right) \\ 0 & 1 \end{bmatrix} \quad (2.41)$$

Les transformations représentées par chacune de ces trois matrices correspondent uniquement à une translation des lignes ou des colonnes de l'image. Ces translations font appel à des interpolations 1-D réalisées en utilisant l'une des méthodes présentées en partie 2.4.1.2.

La figure 2.11 illustre les transformations appliquées à l'image lors des trois étapes de cette rotation. L'angle de rotation est $\theta_k = \pi/4$. La première et la troisième étape de la rotation effectuent un décalage Δ_x de chaque ligne proportionnel à l'ordonnée de celle-ci : $\Delta_x = y \cdot \tan\left(\frac{\theta_k}{2}\right)$. De la même manière la deuxième étape effectue une translation des colonnes : $\Delta_y = -x \cdot \sin(\theta_k)$.

Cette méthode d'interpolation est rapide, de complexité croissant linéairement avec le nombre de pixels de l'image, contrairement au processus de rotation classique dont la complexité varie linéairement avec le carré du nombre de pixels de l'image [Uns 95].

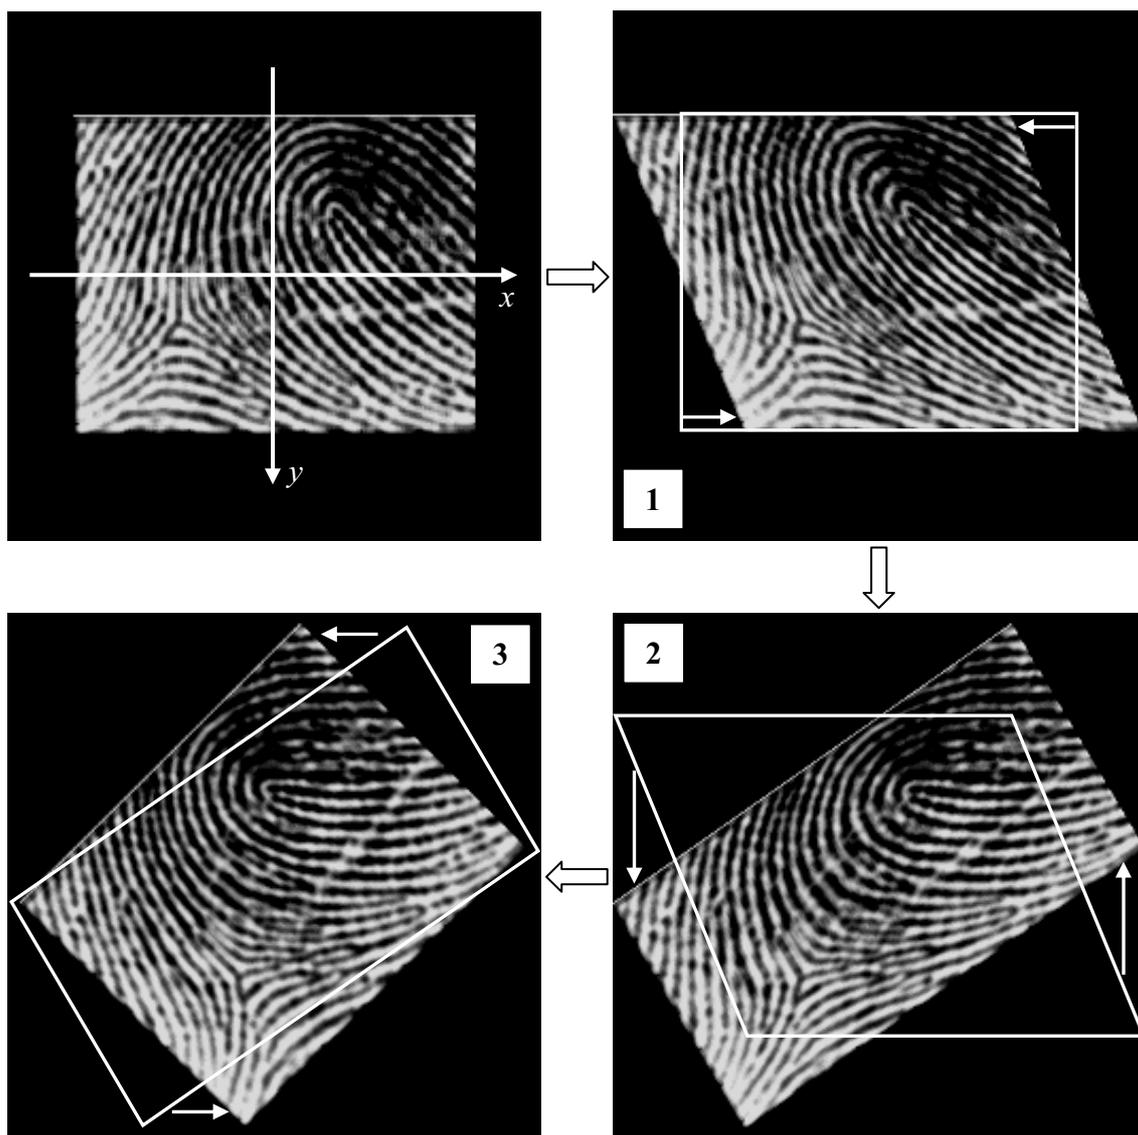


Fig. 2.11 Méthode de rotation rapide en 3 passes

2.4.2.5 Calcul rapide de l'attribut

Pour chaque angle θ_k testé, l'estimation de l'homogénéité se fait sur l'intégralité de l'image ayant subi une rotation d'angle $-\theta_k$.

Pour évaluer l'attribut de réseau, nous pouvons maintenant utiliser directement les valeurs présentes sur la grille des pixels de l'image ayant subi la rotation, les réseaux appliqués étant horizontaux (Fig. 2.10).

Nous calculons cet attribut en tout point de cette image tournée. D'un point à son voisin, ce réseau de lignes se recouvre largement. La valeur de l'attribut change donc peu, et ce changement peut être déterminé.

Nous pouvons donc calculer la valeur recherchée en un point à partir de la valeur calculée sur le point précédent, en effectuant une simple mise à jour (détails en Annexe G).

En plus de permettre la diminution du coût calculatoire dû aux interpolations, notre méthode de calcul utilisant la rotation de l'image plutôt que la rotation du réseau présente donc un autre intérêt : nous pouvons calculer récursivement l'attribut sur toute l'image.

Ce calcul récursif s'effectue tout d'abord indépendamment pour chaque ligne, puis la somme des lignes est effectuée également récursivement.

Afin de diminuer encore le temps de calcul, nous pouvons réduire le nombre de rotations d'images nécessaires à l'estimation de l'orientation. Sur une image tournée d'angle $-\theta_k$, nous évaluons par des réseaux horizontaux l'homogénéité dans la direction θ_k modulo π et nous pouvons également évaluer par des réseaux verticaux l'homogénéité dans la direction $\theta_k + \pi/2$ modulo π .

Dans le cas où nous estimons l'orientation sur un réseau asymétrique, nous réduisons encore le nombre de rotations nécessaires. Chaque image tournée sert à l'estimation l'homogénéité pour les angles θ_k , $\theta_k + \pi/2$, $\theta_k + \pi$ et $\theta_k + 3\pi/2$, c'est-à-dire dans les directions horizontales et verticales, et dans les deux sens.

Ainsi pour tester N_S orientations dans le cas symétrique, nous avons besoin d'effectuer $N_S/2$ rotations d'images et N_S rotations inverses de résultats. Dans le cas asymétrique, pour tester N_A orientations, nous avons besoin de $N_A/4$ rotations d'images et de N_A rotations inverses.

Pour un même pas angulaire T_θ , le nombre de rotations nécessaires à la version asymétrique est malgré tout plus important, en effet nous avons alors $N_A = 2N_S$.

2.4.2.6 Coût calculatoire

Il convient de dissocier le coût calculatoire des rotations de l'image du coût de calcul de l'attribut.

En ce qui concerne les rotations, chaque translation d'un pixel, effectuée à l'aide d'une B-spline de degré n correspond à un coût calculatoire de : $(2n.Mult + (2n - 1).Add)$ [Uns 95].

Or, pour une image I de dimensions $D_{I,x}$ et $D_{I,y}$, nous devons effectuer un nombre $D_{I,x} \cdot D_{I,y} + 2 \cdot (D_{I,x}^2 + D_{I,y}^2)$ de translations pour chaque rotation de l'image, puis un nombre $5 \cdot (D_{I,x}^2 + D_{I,y}^2)$ de translations pour chaque rotation inverse (notons que $\sqrt{D_{I,x}^2 + D_{I,y}^2}$ représente ce côté majoré de l'image tournée, et donc $D_{I,x}^2 + D_{I,y}^2$ représente le nombre de points de cette image). Le coût de chaque rotation d'image est donc :

$$(2n.Mult + (2n - 1).Add) \cdot (D_{I,x} \cdot D_{I,y} + 2 \cdot (D_{I,x}^2 + D_{I,y}^2)).$$

$$\text{Et le coût de chaque rotation inverse est : } 5 \cdot (2n.Mult + (2n - 1).Add) \cdot (D_{I,x}^2 + D_{I,y}^2).$$

En ce qui concerne le coût calculatoire des attributs d'homogénéité, ce coût se décompose entre :

- le calcul initial de l'attribut en début de chaque ligne de l'image,
- sa mise à jour pour tous les autres points de cette ligne,
- la somme récursive des attributs des L lignes constituant le réseau en chaque point.

Nous examinons ici le cas d'un réseau constitué de L lignes et de p points par ligne.

Pour l'attribut fondé sur la variationnelle des niveaux de gris, l'initialisation de chaque ligne requiert $(p-1).Add$ et la mise à jour nécessite $4.Add$ par point. Pour l'attribut fondé sur la variance, l'initialisation présente un coût de $(p+2)Mult + (2p+1)Add$ et la mise à jour a un coût de $5.Mult + 5.Add$

Quel que soit l'attribut calculé, la somme des attributs pour chaque ligne du réseau est initialisé avec un coût $(L-1).Add$ pour chaque colonne et la mise à jour ne demande que $2.Add$ par point.

Les coûts calculatoires d'évaluation des attributs sont donc, pour chaque rotation de l'image :

- pour la variationnelle : $(p+L-2).Add.\sqrt{D_{I,x}^2 + D_{I,y}^2} + 6.Add.(D_{I,x}^2 + D_{I,y}^2)$

- pour la variance :

$((p+2)Mult + (2p+L)Add).\sqrt{D_{I,x}^2 + D_{I,y}^2} + (5.Mult + 7.Add).(D_{I,x}^2 + D_{I,y}^2)$

2.4.2.7 Bilan sur l'implantation, opérateur IRON

L'utilisation de rotations de l'image nous permet de garantir l'isotropie des résultats obtenus (contrairement au Réseau Orienté de Lignes [LeP 01]).

Ces rotations d'images nous permettent également le calcul récursif de notre attribut sur toute l'image.

Notre opérateur, prenant la forme d'un réseau orienté et implanté en utilisant une méthode permettant un calcul récursif de l'attribut, est appelé IRON (Isotropic and Recursive Oriented Network) [Mic 04][Mic 05].

2.5 Influence des paramètres sur les performances de l'opérateur IRON

2.5.1 Estimation d'une seule orientation

2.5.1.1 Evaluation de l'influence des paramètres

Les différents paramètres de l'opérateur IRON sont le choix de l'attribut (variance ou variationnelle), l'échantillonnage de la réponse angulaire, la symétrie du réseau, l'échelle d'analyse ainsi que le facteur de forme.

Nous souhaitons tout d'abord quantifier l'influence de ces paramètres dans le cas de l'estimation d'une orientation unique en chaque point.

Cette évaluation est conduite sur des textures de synthèse, dont nous connaissons l'orientation théorique.

L'influence des paramètres du réseau sera quantifiée par la moyenne sur chaque image de l'erreur d'estimation de l'orientation, calculée grâce à l'EAM (l'Ecart Angulaire Moyen).

Cet Ecart Angulaire Moyen est décrit dans [Mar 72]. L'expression de l'EAM est, pour une image I dont l'orientation θ est estimée par $\hat{\theta}$ en N_I pixels de l'image :

$$EAM = \frac{1}{N_I} \sum_{k=1}^{N_I} \Delta_{\pi}(\theta_k - \hat{\theta}_k) \quad (2.42)$$

La fonction Δ_{π} mesure l'écart absolu modulo π entre deux angles. Son expression est :

$$\Delta_{\pi}(\theta_1, \theta_2) = \min(|\theta_1 - \theta_2|, \pi - |\theta_1 - \theta_2|) \quad (2.43)$$

Le principal avantage de l'indicateur EAM est qu'il prend en compte à la fois le biais de l'opérateur, l'erreur de quantification et la fluctuation de l'estimation de l'orientation due au bruit.

Son seul inconvénient est qu'il nécessite la connaissance de l'orientation locale théorique, ce qui en limite l'usage aux images de synthèse.

2.5.1.2 Influence de la symétrie

Utiliser un opérateur asymétrique permet d'estimer des orientations modulo 2π sur une image. Pour un angle de réseau θ_k donné, et pour deux réseaux ayant la même échelle d'analyse E_0 et le même facteur de forme F_0 , la taille $D_L \times D_R$ du support de calcul du réseau asymétrique est plus petite que celle du réseau symétrique, et ce d'un facteur

$$\text{multiplicatif} \frac{(D_L \times D_R)_{sym}}{(D_L \times D_R)_{asym}} = \frac{4}{\frac{1}{4} + F^2}.$$

Ainsi, dans le cas où nous cherchons à estimer une seule orientation et pour une analyse à une échelle donnée, l'utilisation d'un réseau asymétrique n'apporte non seulement aucun avantage mais de plus réduit le nombre de points pris en compte pour chaque orientation.

C'est pourquoi nous utilisons exclusivement des réseaux symétriques lorsque nous cherchons à estimer l'orientation dans des images ne présentant pas d'orientations multiples, ou lorsque seule l'orientation principale en chaque point nous importe.

2.5.1.3 Influence de l'échantillonnage de la réponse angulaire

Afin d'étudier l'influence du pas d'échantillonnage T_θ sur l'estimation de l'orientation, nous évaluons l'erreur d'estimation en fonction de l'orientation présente dans l'image.

L'image I est une image non bruitée de profil générateur sinusoïdal. Dans une telle image, une seule orientation θ est présente en tout point, quelle que soit l'échelle d'observation (Fig. 2.12). La période de cette image est de 10 pixels, et nous effectuons une estimation de l'orientation pour des angles θ variant de $-\pi$ à π .

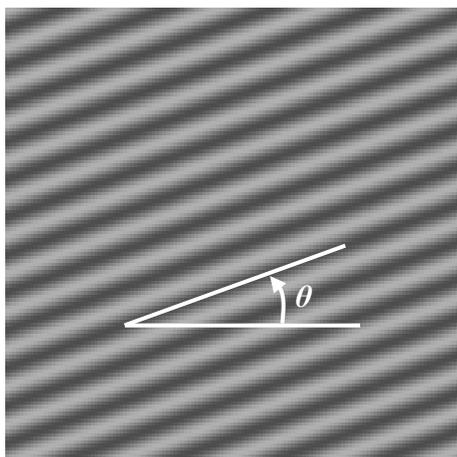


Fig. 2.12 Image d'entrée : texture de profil sinusoïdal

Le pas d'échantillonnage T_θ est fixé à 1° . L'échelle du réseau est $E \approx 5$ pixels et son facteur de forme est $F = 1$, ce qui correspond à un réseau de $L = 7$ lignes et $p = 7$ points par ligne.

L'estimation de l'orientation est effectuée par les deux attributs d'homogénéité, à savoir la variationnelle et la variance.

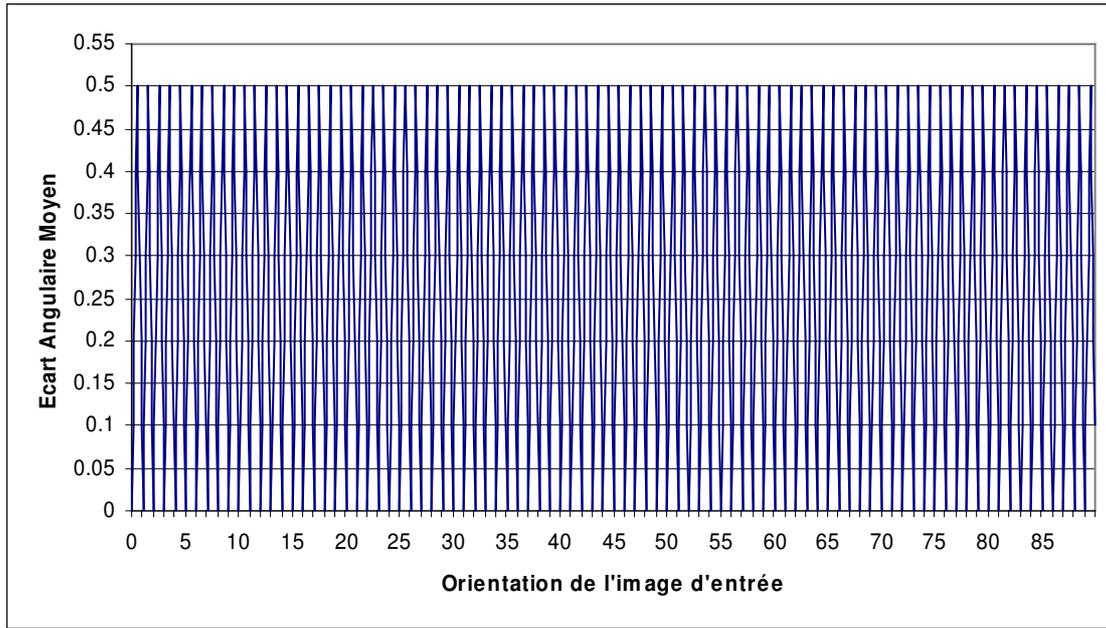


Fig. 2.13 EAM en fonction de l'orientation de l'image étudiée

Le tracé obtenu est le même pour les deux attributs et symétrique par rapport à l'origine (Fig. 2.13).

Puisque l'estimation de l'orientation se fait en absence de bruit, l'erreur totale d'estimation de l'opérateur IRON correspond à la somme du biais dû à la quantification et du biais propre à notre opérateur. Nous retrouvons donc le biais lié à notre méthode de l'estimation de l'orientation en effectuant la différence entre l'erreur mesurée et l'erreur théorique.

L'erreur théorique due à cette quantification s'exprime sous la forme :

$$\Delta_\pi(\theta, \hat{\theta}) = T_\theta \cdot \text{Err}\left(\frac{\theta}{T_\theta}\right) \quad (2.44)$$

Pour un pas d'échantillonnage $T_\theta = 1^\circ$ (Fig. 2.13), la courbe d'erreur mesurée correspond exactement à l'erreur liée à la quantification des orientations.

Le biais d'estimation de l'opérateur IRON sur une telle texture est donc nul quelle que soit l'orientation étudiée.

Il pourrait cependant exister des erreurs minimales liées à l'implantation numérique de l'opérateur (comme les erreurs d'interpolations par exemple) qui ne sont pas mesurables avec le pas d'échantillonnage utilisé.

Afin de le vérifier, nous procédons donc à une estimation de l'orientation sur des images dont l'orientation est comprise dans la plage angulaire située entre les angles θ_0 et $\theta_0 + 0.1^\circ$, avec un pas d'échantillonnage $T_\theta = 0.02^\circ$. Nous montrons ici l'estimation effectuée pour $\theta_0 = 20^\circ$.

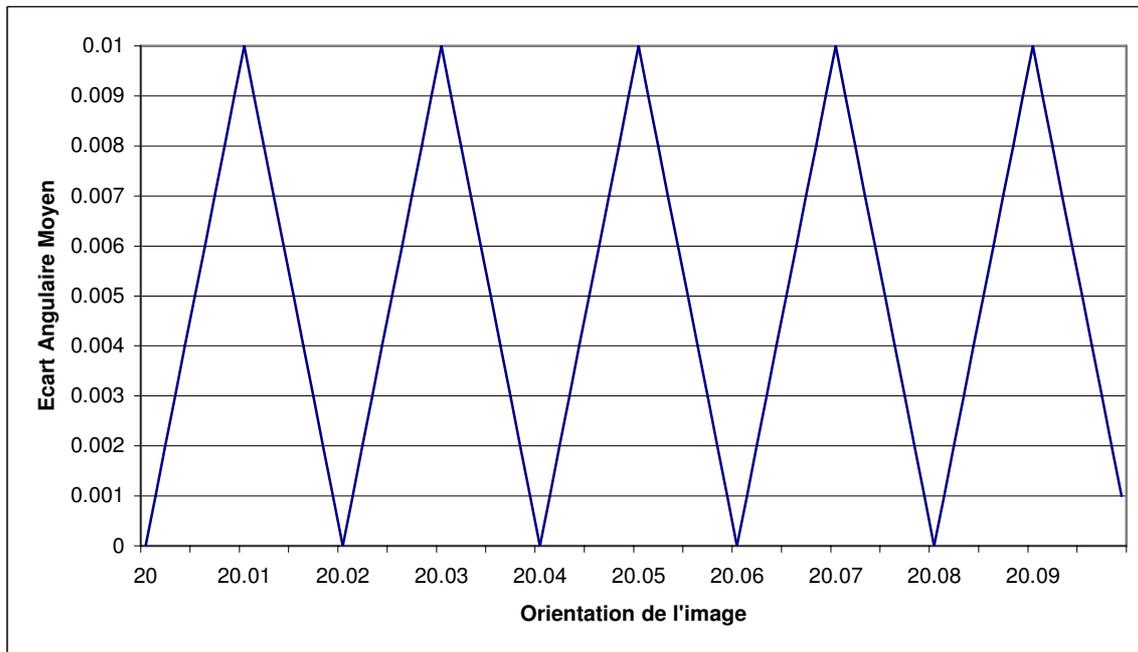


Fig. 2.14 EAM en fonction de l'orientation de l'image

Une fois encore la courbe d'erreur obtenue correspond exactement à l'erreur théorique de quantification : nous ne mesurons aucun biais lié à l'erreur d'estimation de l'orientation par l'opérateur IRON (Fig. 2.14).

Nous avons vérifié que, sur une telle texture synthétique, notre méthode d'estimation de l'orientation ne présente aucun biais, et ce pour une mesure allant jusqu'à 10^{-8} degrés.

2.5.1.4 Influence de l'échelle d'analyse

A priori, l'échelle d'analyse influe essentiellement sur deux aspects de l'estimation de l'orientation : le caractère local ou non de l'estimation de l'orientation et la sensibilité au bruit.

Estimation de l'orientation locale

Nous étudions tout d'abord l'influence de l'échelle sur le caractère local de l'estimation de l'orientation. Pour cela nous devons utiliser une image pour laquelle l'orientation à petite échelle diffère de l'orientation à grande échelle.

Une image de synthèse générée par une fonction profil h , modulée en orientation correspond à une telle description. L'équation utilisée pour la synthèse de cette image est la suivante :

$$f_{\theta_0, \theta_i}(x, y) = h(t_{\theta_0} + m(t_{\theta_i})) , t_{\theta_i} = x \cdot \sin(\theta_i) + y \cdot \cos(\theta_i) \quad (2.45)$$

Pour cette étude, nous utilisons une texture de fonction génératrice h sinusoïdale, modulée en orientation par une fonction m également sinusoïdale :

$$h(t_{\theta_0}, t_{\theta_1}) = \cos\left(\frac{2\pi}{T}\left(t_{\theta_0} + A \cdot \cos\left(\frac{2\pi}{T_{\text{mod}}}(t_{\theta_1})\right)\right)\right) \quad (2.46)$$

L'orientation théorique de cette image est :

$$\theta(x, y) = -\arctan\left(\frac{\frac{\partial h(t_{\theta_0}, t_{\theta_1})}{\partial y}}{\frac{\partial h(t_{\theta_0}, t_{\theta_1})}{\partial x}}\right) = -\arctan\left(\frac{\sin(\theta_0) - \cos(\theta_0) \cdot \frac{2\pi}{T_{\text{mod}}} A \cdot \sin\left(\frac{2\pi}{T_{\text{mod}}}(t_{\theta_1})\right)}{\cos(\theta_0) + \sin(\theta_0) \cdot \frac{2\pi}{T_{\text{mod}}} A \cdot \sin\left(\frac{2\pi}{T_{\text{mod}}}(t_{\theta_1})\right)}\right) \quad (2.47)$$

Les orientations locales dans une telle image varient continûment sur un large intervalle. Un EAM indépendant de l'orientation peut donc être calculé sur une seule image. Nous choisissons que la modulation d'orientation agisse dans la direction θ_1 perpendiculaire à la direction non modulée θ_0 de la texture (Fig. 2.15). Les paramètres de l'image sont : $\theta_0 = 20^\circ$, $\theta_1 = 110^\circ$, $T = 10 \text{ pixels}$, $T_{\text{mod}} = 50 \text{ pixels}$ et $A = 4$. Le pas d'échantillonnage vaut $T_\theta = 1^\circ$.

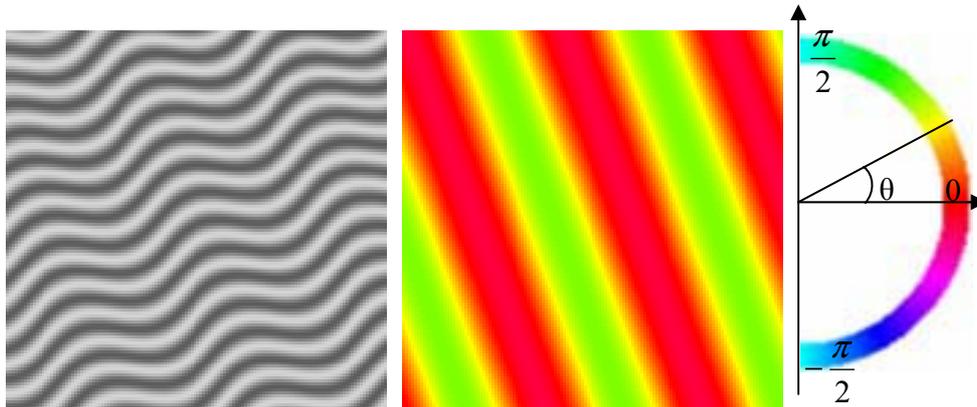


Fig. 2.15 Image étudiée, orientation théorique et palette d'orientation

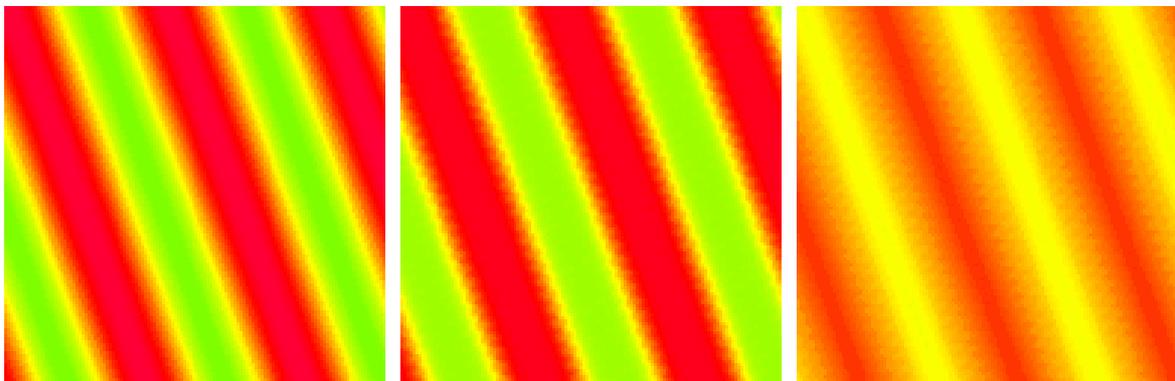


Fig. 2.16 Estimation de l'orientation par la variationnelle
(de gauche à droite : $E \approx 5$, $E \approx 15$ et $E \approx 45$)

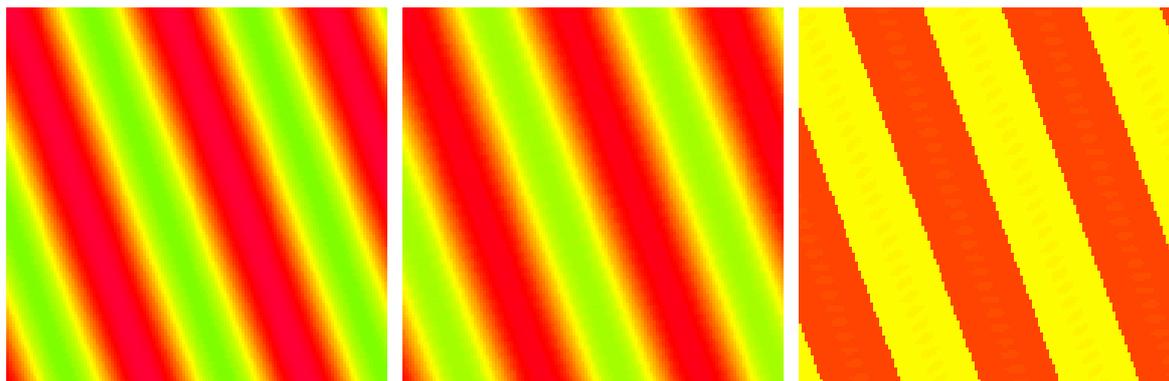


Fig. 2.17 Estimation de l'orientation par la variance
(de gauche à droite : $E \approx 5$, $E \approx 15$ et $E \approx 45$)

Le tableau suivant rassemble les erreurs d'estimations de l'orientation obtenues sur ces images en fonction de l'échelle E et de l'attribut de réseau utilisé.

L'EAM est calculé en prenant comme référence l'orientation locale ou l'orientation globale de l'image.

	Taille	E	EAM à $\theta(x, y)$	EAM à $\theta_0 = 20^\circ$
Variationnelle	7×7	5	0.438	17.4
	21×21	15	2.02	17.5
	63×63	45	24.6	9.85
Variance	7×7	5	0.397	17.1
	21×21	15	2.79	14.7
	63×63	45	28.3	10.9

Tab. 2.1 Erreurs d'estimation en fonction de l'échelle E

Pour les deux attributs utilisés (Fig. 2.16 et Fig. 2.17), nous observons que lorsque l'échelle E de l'opérateur augmente, l'erreur d'estimation de l'orientation locale augmente (Tab. 2.1). Dans le même temps et très logiquement, l'erreur d'estimation de l'orientation globale diminue.

Il en découle naturellement que pour estimer l'orientation locale sur une image dont l'orientation varie en fonction de la position étudiée, il convient de procéder à une analyse à une échelle aussi petite que possible.

Estimation de l'orientation sur une image bruitée

Nous étudions maintenant la résistance au bruit de l'opérateur IRON en fonction de son échelle d'analyse E . Nous procédons pour cela à une estimation de l'orientation sur des images correspondant à notre modèle (Eq. 1.2), avec un profil h sinusoïdal de période 10 pixels, non modulé en orientation (Fig. 2.18). Ces images sont bruitées à divers rapports signal à bruit (RSB) par un bruit blanc gaussien uniforme.

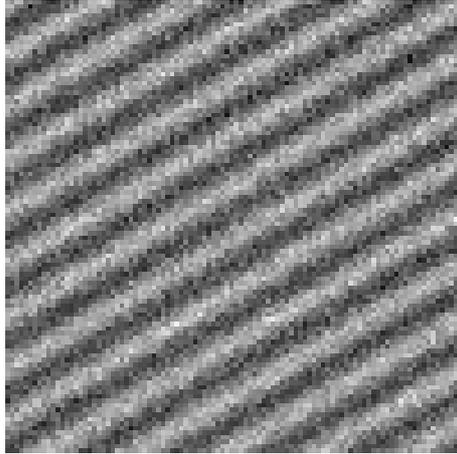


Fig. 2.18 Image de profil sinusoïdal bruitée (RSB=5dB)

La valeur d'EAM indiquée correspond à la moyenne sur 100 images d'orientations θ différentes, uniformément réparties sur un intervalle angulaire de largeur T_θ . Dans une telle configuration, l'erreur moyenne $\bar{\Delta}_{T_\theta}$ due à la quantification des orientations vaut :

$$\bar{\Delta}_{T_\theta} = \int_{\theta=\theta_0}^{\theta_0+T_\theta} T_\theta \cdot \text{Err}\left(\frac{\theta}{T_\theta}\right) = \frac{T_\theta}{4} \quad (2.48)$$

Dans le cas où nous choisissons $T_\theta = 1^\circ$, cette erreur moyenne liée à la quantification de l'orientation vaut $\bar{\Delta}_{T_\theta} = 0.25^\circ$. Ceci constitue donc la plus petite erreur moyenne d'estimation possible. L'effet du bruit sur l'estimation de l'orientation ne sera donc perceptible qu'au-delà de cette valeur de 0.25° .

En effectuant l'estimation de l'orientation sur plusieurs images d'orientation différentes, l'erreur d'estimation de l'orientation devient indépendante de l'orientation de l'image d'entrée. Nous avons également un grand nombre de réalisations du bruit, permettant de calculer une erreur moyenne pour un RSB donné.

	Taille	E	RSB = 20dB	RSB = 10dB	RSB = 5dB	RSB = 0dB
Variationnelle	7×7	5	1.55	6.04	12.5	23.0
	21×21	15	0.838	2.59	10.8	16.0
	63×63	45	0.541	1.54	2.63	5.19
Variance	7×7	5	0.664	2.01	3.85	7.51
	21×21	15	0.253	0.335	0.555	0.987
	63×63	45	0.250	0.250	0.252	0.259

Tab. 2.2 Erreur moyenne d'estimation en fonction de l'échelle E et du RSB

La présence de bruit, augmentant l'écart de l'image au modèle, entraîne des erreurs d'estimation de l'orientation. Quel que soit l'attribut de réseau utilisé, nous observons qu'une analyse à plus grande échelle permet comme prévu de minimiser l'influence du bruit sur l'estimation de l'orientation (Tab. 2.2).

Nous remarquons également que l'attribut d'homogénéité fondé sur la variance des niveaux de gris fournit une estimation de l'orientation plus robuste au bruit gaussien appliqué à l'image. Ceci confirme les conclusions tirées lors de l'étude théorique des opérateurs, au paragraphe 2.3.2.3.

Conclusion sur l'influence de l'échelle d'analyse

Ainsi une analyse à petite échelle permet d'estimer les orientations au niveau local mais alors la faible taille du support de calcul de notre réseau augmente la sensibilité au bruit. A l'opposé, une analyse à grande échelle permet de diminuer sensiblement l'influence du bruit sur l'estimation, mais masque les variations locales de l'orientation pour ne conserver que la tendance directionnelle à grande échelle.

Le choix de l'échelle E de notre réseau fera donc l'objet d'un compromis entre le caractère local de l'estimation des orientations et la robustesse au bruit.

2.5.1.5 Influence de la forme du réseau

Dans le cas où nous ne cherchons à estimer qu'une seule orientation en chaque point de l'image, le facteur de forme F de notre réseau n'influe, pour une échelle donnée, que sur la résistance au bruit de l'opérateur IRON.

Afin d'évaluer l'influence de la forme du réseau sur la robustesse de l'estimation nous procédons de la même manière que pour l'échelle d'analyse. Les images étudiées sont des textures de profil sinusoïdal, de mêmes paramètres que précédemment.

Pour différents facteurs de forme F_i , nous faisons varier le RSB de l'image d'entrée, et ce pour les deux attributs calculés sur le réseau.

L'échelle est fixée à $E \approx 15$, et les facteurs de formes utilisés sont $F \in \left\{1, \frac{1}{2}, \frac{1}{3}, \frac{1}{4}\right\}$, ce qui correspond à des réseaux de dimensions $(D_L, D_R) \in \{(21,21), (13,27), (9,27), (7,29)\}$.

	F	RSB = 20dB	RSB = 10dB	RSB = 5dB	RSB = 0dB
Variationnelle	1	0.846	2.60	13.4	17.9
	0.5	0.860	2.89	14.7	18.9
	0.33	0.983	3.57	14.4	19.2
	0.25	1.05	4.67	13.8	19.2
Variance	1	0.253	0.337	0.560	0.995
	0.5	0.252	0.312	0.489	0.853
	0.33	0.254	0.344	0.569	0.972
	0.25	0.255	0.340	0.564	0.981

Tab. 2.3 Erreur moyenne en fonction de la forme F et du RSB

Nous remarquons que le facteur de forme F n'a que peu d'influence sur la robustesse au bruit de l'estimation de l'orientation (Tab. 2.3). En effet, bien que la taille du support de calcul pour une orientation donnée diminue quand F diminue, la dimension radiale D_R

augmente, permettant de compenser par une plus grande sensibilité au signal la perte de résistance au bruit.

2.5.2 Estimation d'orientations multiples

Nous testons la capacité du réseau symétrique à détecter les orientations multiples en utilisant un test ayant déjà été mis en oeuvre dans la littérature [Che 98].

L'objectif est d'estimer deux orientations en un même point, ces deux orientations étant séparées par un angle $\Delta\theta$ variable. Plus l'opérateur IRON sera apte à détecter et estimer deux orientations proches, plus sa sélectivité angulaire sera importante.

Protocole expérimental

L'image étudiée correspond à la superposition de deux lignes de profil gaussien, de variance σ_L et d'orientations respectives θ_1 et θ_2 (Fig. 2.19) :

$$L_{\theta,\sigma_L}(x,y) = \exp\left(-\frac{(x.\cos(\theta) - y.\sin(\theta))^2}{2.\sigma_L}\right) \quad (2.49)$$

Lors de nos expérimentations, nous prendrons $\sigma = 2$.

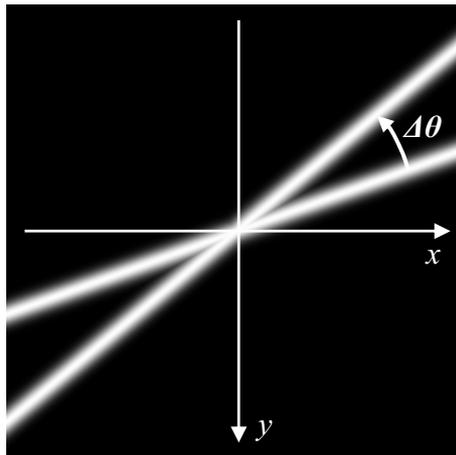


Fig. 2.19 Deux lignes gaussiennes

La réponse angulaire $H(0,0,\theta_k)$ obtenue au centre de l'image fait apparaître deux maxima locaux pour les orientations θ_1 et θ_2 et un minimum local entre celles-ci, pour un angle intermédiaire que nous appellerons θ_i .

La figure 2.20 présente une telle réponse, entre -90° et 90° , pour un réseau de paramètres $E \approx 10$ et $F = 0.25$, utilisant la variationnelle des niveaux de gris comme indicateur de désordre.

Nous réalisons une mesure expérimentale de la différence d'angle minimale $\Delta\theta_{\min}$ nécessaire pour que l'opérateur IRON distingue les deux orientations présentes.

Nous mesurons également la différence d'angle $\Delta\theta_0$, pour laquelle l'estimation des deux orientations se fait avec un biais inférieur au pas d'échantillonnage T_θ de la réponse angulaire.

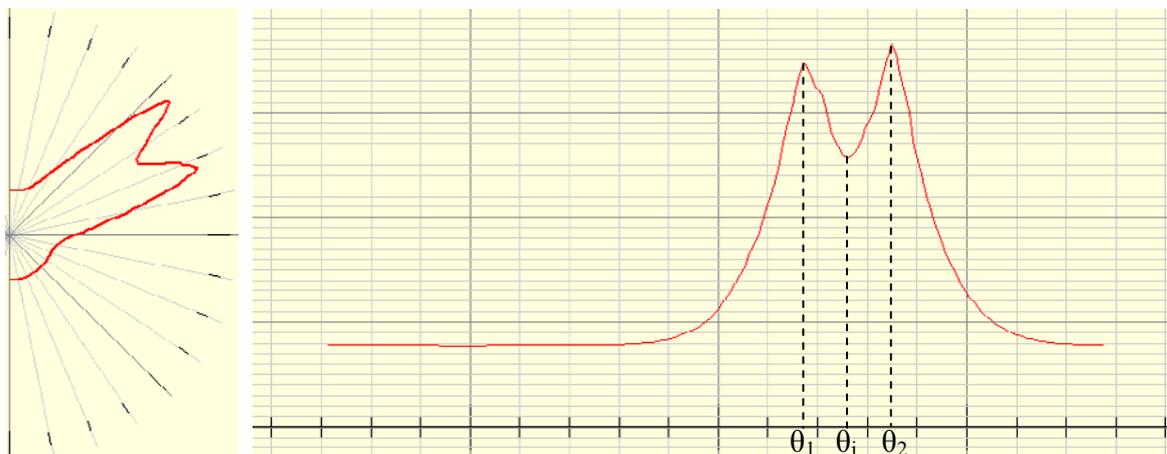


Fig. 2.20 Réponse angulaire au point central.

De plus, à titre de comparaison avec [Che 98] nous mesurons la différence d'angle $\Delta\theta_{50\%}$ pour laquelle :

$$\frac{H(\theta_i)}{(H(\theta_1) + H(\theta_2))/2} \geq 50\%$$

Cependant, pour plus de clarté, nous ne présentons dans ce chapitre que les valeurs $\Delta\theta_{\min}$ et $\Delta\theta_0$ (les courbes pour $\Delta\theta_{50\%}$ peuvent être consultées en Annexe H).

Nous effectuons les expérimentations pour des valeurs d'échelle comprises entre 5 et 45 pixels, et pour des facteurs de forme allant de 0.1 à 1.

Le pas d'échantillonnage T_θ vaut 1° , θ_1 est fixé à 20° et nous faisons varier θ_2 de la valeur θ_1 à $\theta_1 + 90^\circ$ par pas de 1° . Avec de tels paramètres, chaque valeur de θ_1 et θ_2 correspond exactement à une des orientations testées.

Résultats

Dans les figures suivantes, les courbes liées à l'attribut variationnel sont en rouge (trait fin), celles liées à l'attribut fondé sur la variance en bleu nuit (trait épais). Les valeurs $\Delta\theta_{\min}$ correspondent aux courbes continues, les valeurs $\Delta\theta_0$ aux courbes en traits pointillés.

Sur le tracé correspondant à l'échelle $E=5$ (Fig. 2.21), la courbe de $\Delta\theta_0$ n'apparaît pas pour la méthode fondée sur la variationnelle des niveaux de gris. En effet, à cette échelle, l'estimation des deux orientations présentes au point étudié se fait systématiquement avec un biais de mesure pour au moins une des deux orientations. Dans le cas présent, ce biais varie de 1° pour un angle $\Delta\theta$ proche de 90° , à 3° quand $\Delta\theta$ approche de 0° .

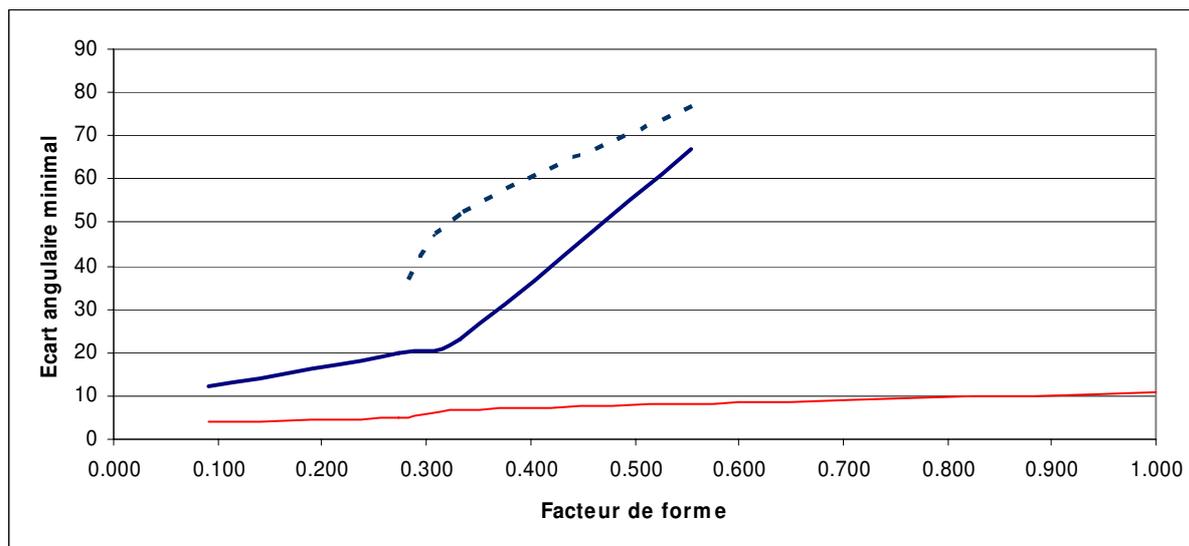


Fig. 2.21 Ecart angulaire minimaux en fonction du facteur de forme F ($E=5$)
(variance : trait épais, variationnelle : trait fin, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

Certains points des courbes liées à la méthode fondée sur la variance ne sont pas non plus renseignés car aucune valeur ne correspond à la condition recherchée sur $\Delta\theta$ (détection des deux orientations ou estimation sans biais).

A cette échelle ($E = 5$) et pour un attribut d'homogénéité donné, la sélectivité angulaire semble être liée au facteur de forme F du réseau : plus ce facteur de forme diminue, plus la sélectivité augmente (Fig. 2.21).

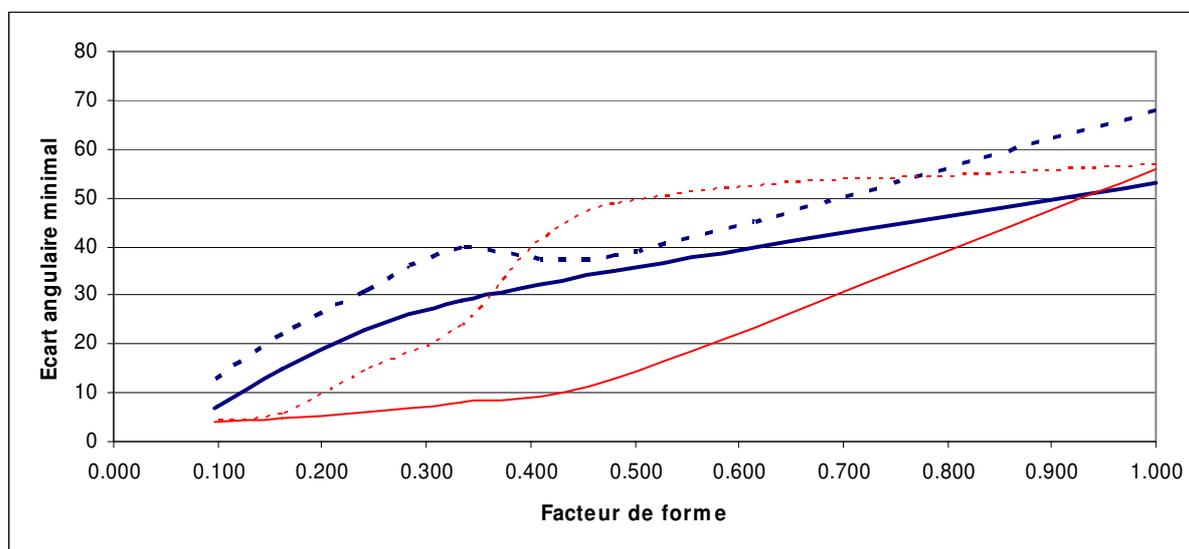


Fig. 2.22 Ecart angulaire minimaux en fonction du facteur de forme F ($E=15$)
(variance : trait épais, variationnelle : trait fin, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

A une échelle intermédiaire ($E = 15$), la sélectivité angulaire de l'opérateur IRON fondé sur une mesure de la variance s'améliore (quel que soit le facteur de forme) (Fig. 2.22).

A l'opposé, la sélectivité angulaire de l'opérateur IRON fondé sur la variationnelle est plus faible pour des facteurs de forme supérieurs à 0.3. En contrepartie, il est maintenant possible d'obtenir une estimation sans biais des deux orientations présentes grâce à cette méthode.

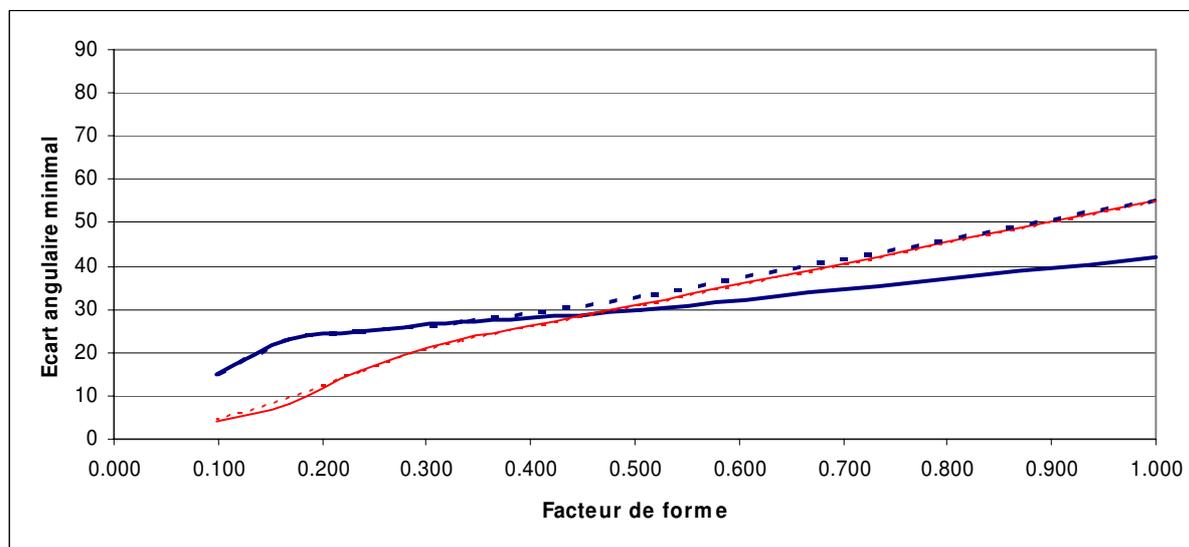


Fig. 2.23 Ecarts angulaires minimaux en fonction du facteur de forme F ($E=45$)
(variance : trait épais, variationnelle : trait fin, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

A plus grande échelle (ici pour $E = 45$), la sélectivité angulaire de l'opérateur fondé sur la variance s'améliore encore pour des facteurs de forme supérieurs à 0.3, alors qu'elle diminue pour des facteurs de forme inférieurs à 0.3. De même la sélectivité angulaire de la méthode reposant sur la variationnelle diminue (Fig. 2.23).

En contrepartie, l'estimation des deux orientations, quand elles sont détectées, se fait presque sans biais (les courbes $\Delta\theta_0$ et $\Delta\theta_{\min}$ sont proches, et presque confondues quand F diminue).

Conclusion sur la sélectivité angulaire

Pour un même réseau, nous remarquons que l'opérateur IRON fondé sur la variationnelle des niveaux de gris se montre plus sélectif que lorsqu'il utilise la variance comme attribut d'homogénéité.

Quand l'échelle E augmente, nous remarquons que la courbe de l'angle minimal $\Delta\theta_0$ pour une estimation non biaisée des deux orientations se rapproche de celle de l'angle minimal $\Delta\theta_{\min}$ nécessaire à la détection des deux orientations : le biais d'estimation d'orientations multiples diminue lorsque l'échelle augmente.

Comme prévu et quel que soit l'attribut utilisé, plus le facteur de forme F est proche de zéro, plus l'opérateur IRON est sélectif angulairement.

Cependant, le facteur de forme F n'est pas le paramètre qui détermine directement la sélectivité de l'opérateur IRON : en effet, pour un même facteur de forme, nous pouvons obtenir une sélectivité angulaire différente en fonction de l'échelle.

Le paramètre déterminant la sélectivité angulaire est la largeur D_L de notre réseau. Dans le cas de figure que nous venons d'étudier, nous obtenons une bonne sélectivité lorsque D_L a une dimension comparable aux éléments de l'image qui définissent son orientation locale.

2.6 Comparaison avec d'autres méthodes d'estimation des orientations

Dans cette partie, nous comparons les performances de l'opérateur IRON à celles d'autres méthodes proposées dans la littérature.

Les méthodes retenues pour la comparaison sont des filtres orientés, capables d'estimer plusieurs orientations en un même point. Dans le cas de l'estimation de l'orientation modulo π , nous effectuerons une comparaison de l'opérateur IRON symétrique avec les filtres de Gabor, deux noyaux de filtres steerable (dans leur version standard ou approximée si nous devons construire ces filtres avec un facteur de forme différent de 1).

Dans le cas d'une estimation des orientations modulo 2π , nous effectuerons une comparaison de notre opérateur asymétrique avec les filtres wedge steerable.

2.6.1 Comparaison des paramètres

Afin de pouvoir comparer équitablement plusieurs méthodes d'estimation de l'orientation, nous devons déterminer le lien existant entre les différents paramètres de celles-ci.

Les paramètres sur lesquels nous allons pouvoir établir une comparaison sont :

- le pas d'échantillonnage T_θ de la réponse angulaire
- l'échelle d'analyse E , qui peut être reliée à la taille M du support de calcul carré des autres méthodes d'estimation. Nous établissons le lien $M = 2 \times E + 1$.
- le facteur de forme F , qui peut être comparé à l'allongement λ des filtres (1.3.2). Une relation simple lie ces deux paramètres : $F = 1/\lambda$.

Nous effectuerons donc des comparaisons entre les différentes méthodes en prenant des valeurs comparables pour ces paramètres.

2.6.2 Biais d'estimation sur une texture idéale non bruitée

De la même manière que pour l'opérateur IRON, nous tenons à examiner le biais d'estimation de l'orientation sur une image non bruitée pour laquelle l'orientation est constante. Nous utilisons une fois de plus une texture sinusoïdale de période texturale 10 pixels, dont nous faisons varier l'orientation de $-\pi$ à π .

Les paramètres des filtres que nous utilisons pour estimer l'orientation sont les suivants :

- pas d'échantillonnage de la réponse angulaire $T_\theta = 1^\circ$,
- échelle des filtre $E = 5$,
- facteur de forme des opérateurs $F = 1$.

Nous prenons pour période centrale des filtres de Gabor $T_0 = 5$ pixels. La période du filtre est choisie différente de la période de l'image afin de pouvoir respecter la condition $\sigma \geq r_\sigma \cdot T_0$ (avec $r_\sigma = 0.4$ dans le cas présent).

Les filtres steerable utilisés sont les filtres E2 et E4 décrits dans [Fre 91].

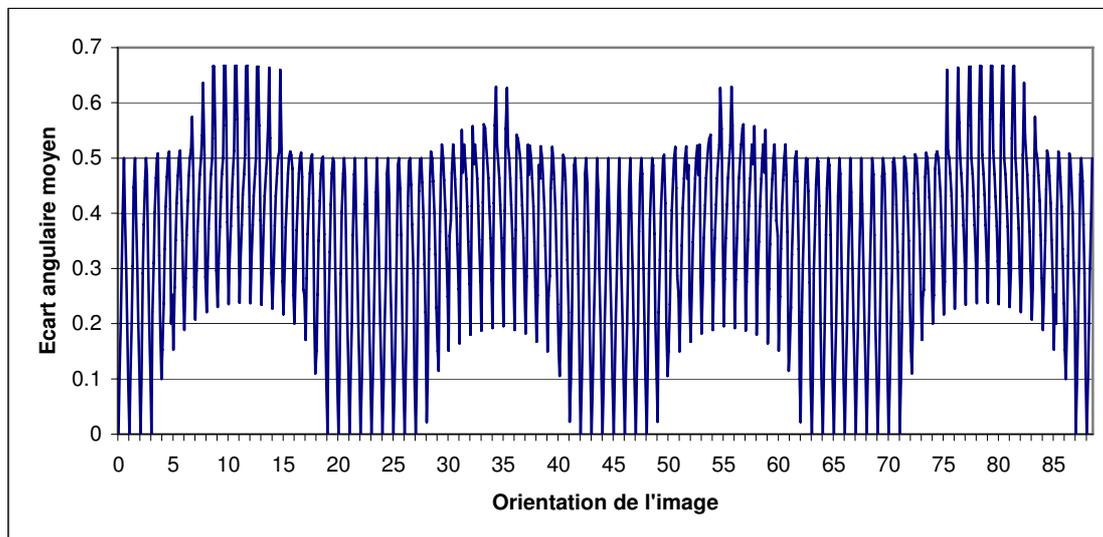


Fig. 2.24 EAM en fonction de l'orientation de l'image pour les filtres de Gabor

Contrairement à la courbe que nous avons obtenue avec l'opérateur IRON, nous remarquons ici que l'erreur de quantification n'est pas la seule source d'erreur pour l'estimation de l'orientation (Fig. 2.24).

Afin d'évaluer le biais d'estimation des filtres de Gabor, nous traçons la différence entre l'EAM et l'erreur due à la quantification (Fig. 2.25).

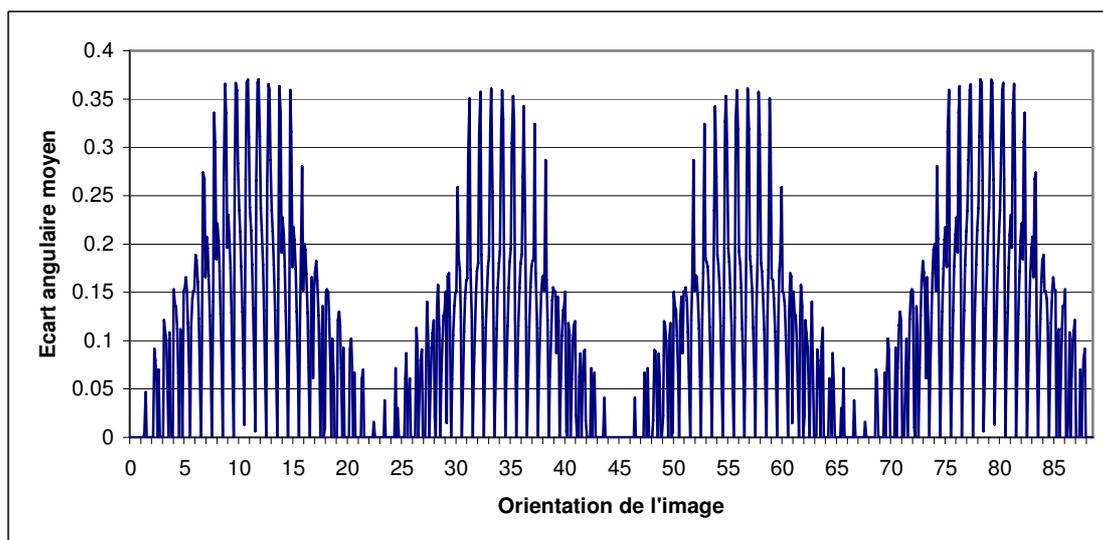


Fig. 2.25 Biais d'estimation pour les filtres de Gabor

Au vu de ce tracé, nous constatons tout d'abord que le biais d'estimation est non nul et peut atteindre 0.37° . D'autre part, ce biais varie en fonction de l'orientation de l'image étudiée.

En réitérant cette estimation du biais avec un filtre de Gabor opérant sur un support de calcul plus grand ($E = 15$) et en prenant une période de filtre égale à la période texturale (soit $T_0 = 10$), le biais d'estimation devient nul quelle que soit l'orientation étudiée. Une analyse à plus grande échelle en gardant une période de filtre $T_0 = 5$ conduit à une estimation de l'orientation très fortement biaisée (EAM d'environ 30° quelle que soit l'orientation étudiée).

Nous étudierons plus en détail cette sensibilité au réglage en fréquence des filtres de Gabor au paragraphe 2.6.5.

De la même manière que pour les filtres de Gabor, nous obtenons les courbes de biais pour les filtres steerable E2 et E4 (Fig. 2.26 et Fig. 2.27).

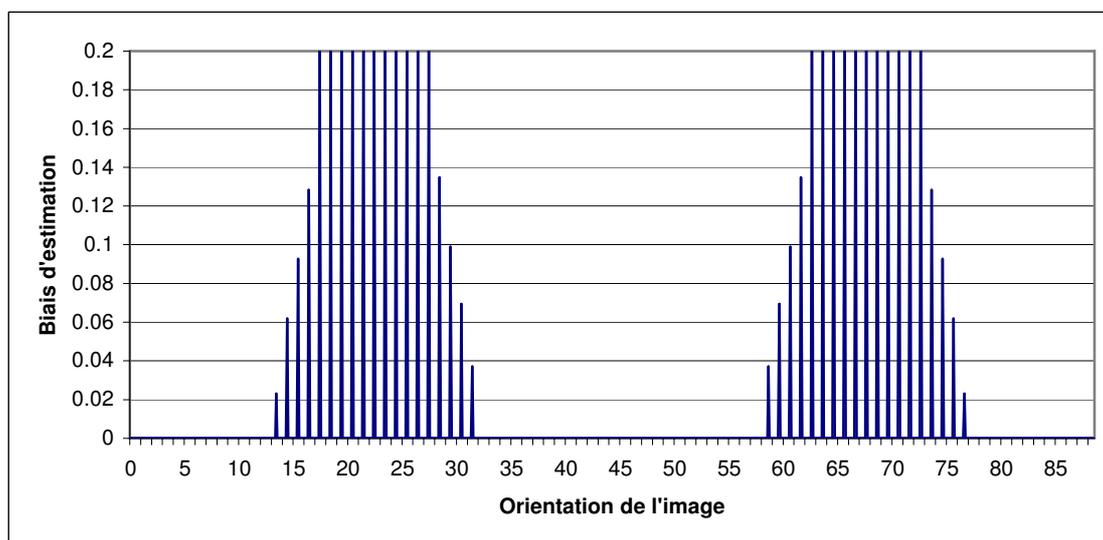


Fig. 2.26 Biais d'estimation pour les filtres steerable (filtre E2)

Le biais lié à l'estimation de l'orientation par les filtres steerable E2 est lui aussi non nul et dépend également de l'orientation de l'image étudiée.

Une estimation de l'orientation à plus grande échelle ($E = 15$) fait diminuer le biais de mesure observé mais ne le fait pas disparaître (courbe en Annexe E).

Enfin, le biais obtenu en estimant l'orientation avec les filtres steerable E4 peut atteindre 2° pour des orientations étudiées proches de $\frac{\pi}{8}$ modulo $\frac{\pi}{4}$ (Fig. 2.27).

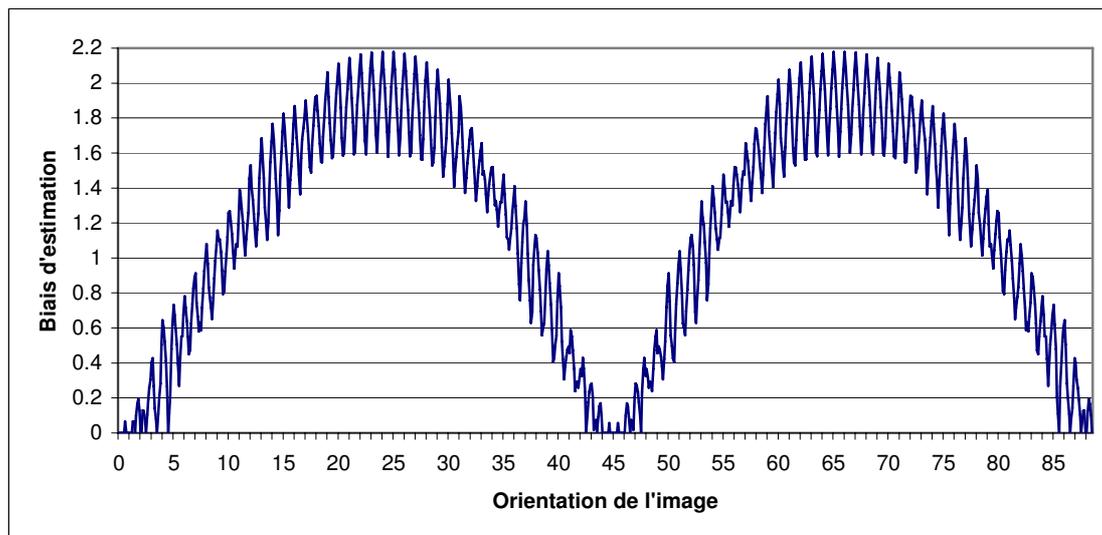


Fig. 2.27 Biais d'estimation pour les filtres steerable (filtre E4)

Comme pour les filtres steerable E2, une estimation de l'orientation à plus grande échelle atténue le biais observé mais ce dernier ne disparaît pas.

Pour les trois méthodes utilisées, nous remarquons que le biais d'estimation de l'orientation n'est pas toujours nul sur une image orientée idéale non bruitée et que ce biais peut dépendre de l'orientation étudiée.

2.6.3 Estimation locale de l'orientation

Pour chacune de ces trois méthodes, nous souhaitons maintenant quantifier le comportement pour l'estimation de l'orientation locale en fonction de l'échelle.

Nous procédons de la même manière que pour l'opérateur IRON, à savoir nous procédons au calcul de l'erreur d'estimation de l'orientation locale et de l'orientation globale pour différentes échelles.

L'image est générée en utilisant la même formule qu'en 2.5.1.4. Les paramètres de l'image sont : $\theta_0 = 20^\circ$, $\theta_1 = \theta_0 + 90^\circ$, $T = 10 \text{ pixels}$, $T_{\text{mod}} = 50 \text{ pixels}$ et $A = 4$ (Fig. 2.28).

Pour toutes les méthodes, le pas d'échantillonnage vaut $T_\theta = 1^\circ$, le facteur de forme vaut $F = 1$. Les échelles d'analyse présentées sont $E \in \{5, 15, 45\}$.

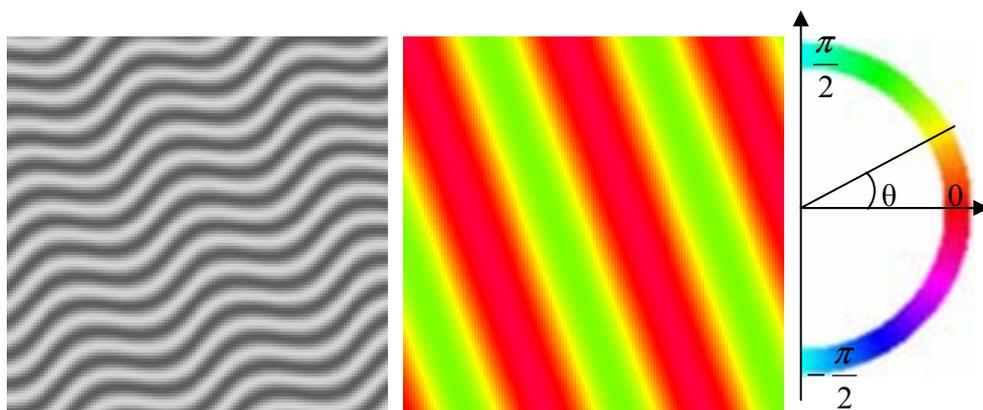


Fig. 2.28 Image étudiée, orientation théorique et palette d'orientation

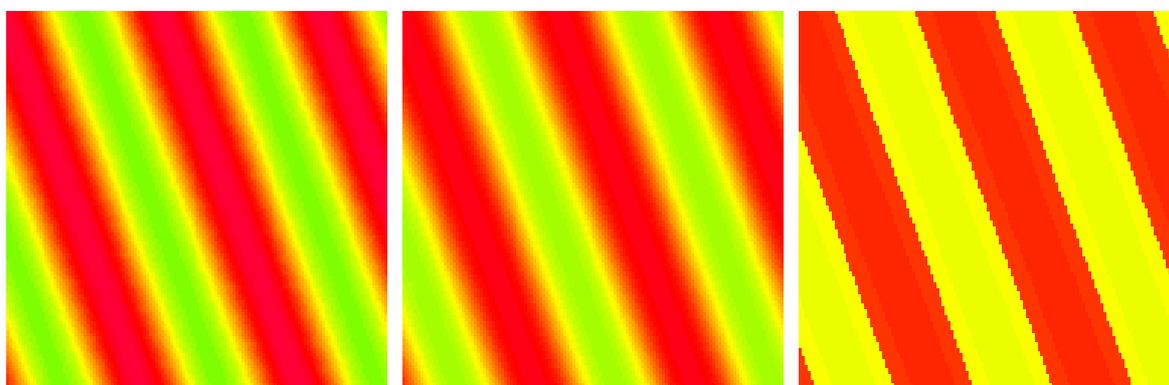


Fig. 2.29 Estimation de l'orientation par les filtres de Gabor
(de gauche à droite : $E=5$, $E=15$ et $E=45$)

D'un point de vue visuel, les résultats obtenus avec les filtres de Gabor sont comparables à ceux obtenus avec l'opérateur IRON utilisant sur la variance des niveaux de gris comme attribut (Fig. 2.17).

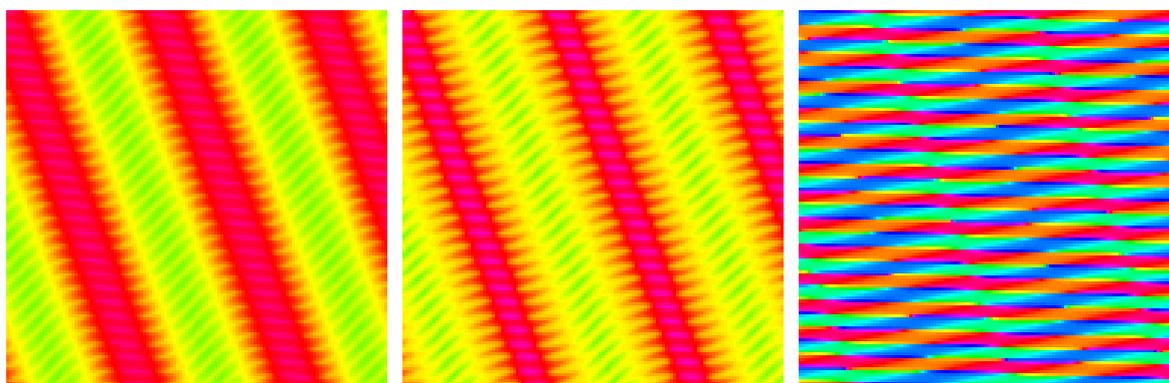


Fig. 2.30 Estimation de l'orientation par les filtres de steerable E_2
(de gauche à droite : $E=5$, $E=15$ et $E=45$)

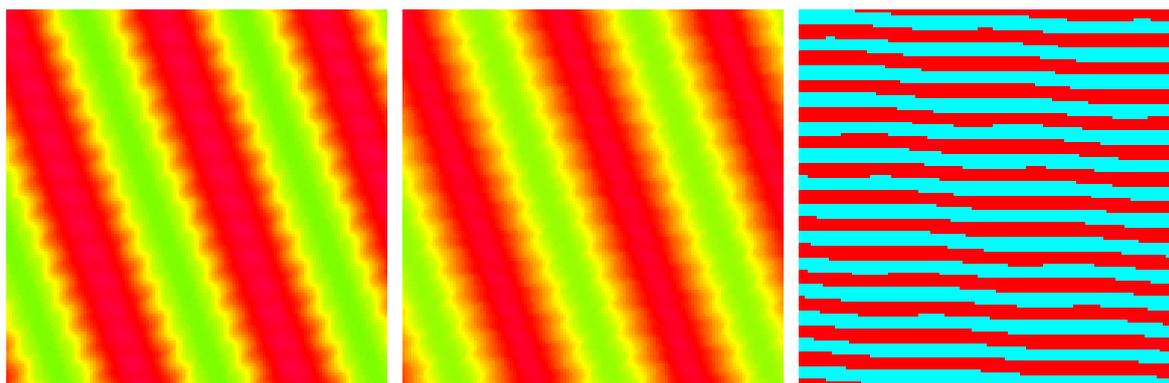


Fig. 2.31 Estimation de l'orientation par les filtres steerable E4
(de gauche à droite : $E=5$, $E=15$ et $E=45$)

Les filtres steerable sont plus sensibles que les autres méthodes aux variations d'échelle : à grande échelle ($E=45$) l'estimation fournie n'est plus significative (Fig. 2.30 et Fig. 2.31).

Les valeurs d'EAM ayant pour référence l'orientation locale ou l'orientation globale sont rassemblées dans le tableau 2.4.

	E	EAM à $\theta(x, y)$	EAM à $\theta_0 = 20^\circ$
Gabor	5	0.410	17.2
	15	2.30	15.1
	45	7.53	13.0
Steerable E2	5	2.67	16.2
	15	6.31	13.8
	45	45.3	45.1
Steerable E4	5	1.03	17.2
	15	2.71	14.8
	45	45.0	44.8

Tab. 2.4 Erreurs d'estimation en fonction de l'échelle E

Ce tableau confirme en particulier que pour les filtres steerable, l'échelle d'analyse $E=45$ ne semble pas du tout adaptée puisque l'EAM est proche de 45° , ce qui correspond à une estimation de l'orientation décorrélée avec l'orientation présente dans l'image.

2.6.4 Immunité au bruit

Nous comparons maintenant l'opérateur IRON aux autres méthodes en termes de robustesse de l'estimation de l'orientation.

Chaque valeur d'EAM fournie correspond à la moyenne calculée sur 180 images dont les orientations sont uniformément réparties entre 0° et 45° . Nous obtenons ainsi des valeurs d'EAM indépendantes de l'angle étudié.

Pour toutes les méthodes utilisées, le pas d'échantillonnage de la réponse angulaire est $T_\theta = 1^\circ$ et le facteur de forme vaut $F = 1$.

	E	RSB = 20dB	RSB = 10dB	RSB = 5dB	RSB = 0dB
Gabor	5	0.944	2.831	5.24	12.3
	15	0.254	0.303	0.393	0.703
	45	0.250	0.251	0.252	0.257
Steerable E2	5	0.596	1.75	3.13	5.89
	15	0.548	1.58	2.82	5.56
	45	44.9	45.4	45.8	44.9
Steerable E4	5	1.73	3.86	11.6	27.2
	15	0.699	0.831	1.09	1.65
	45	44.7	45.4	44.4	45.2
IRON Variationnelle	5	1.55	6.04	12.5	23.0
	15	0.838	2.59	10.8	16.0
	45	0.541	1.54	2.63	5.19
IRON Variance	5	0.664	2.007	3.85	7.51
	15	0.253	0.335	0.555	0.987
	45	0.250	0.250	0.252	0.259

Tab. 2.5 Erreur moyenne d'estimation en fonction de l'échelle E et du RSB

A petite échelle ($E=5$), les filtres steerable E2 sont les moins sensibles au bruit de l'image.

A échelle intermédiaire ($E=15$) et à grande échelle les filtres de Gabor et l'opérateur IRON utilisant l'attribut d'homogénéité fondé sur la variance, présentent la plus faible sensibilité au bruit.

Notons que l'opérateur IRON fondé sur la variance, même s'il n'obtient pas les plus faibles valeurs d'EAM pour chacun des cas de figure étudiés, présente une bonne immunité au bruit, à chaque fois proche des meilleurs résultats obtenus tous opérateurs confondus.

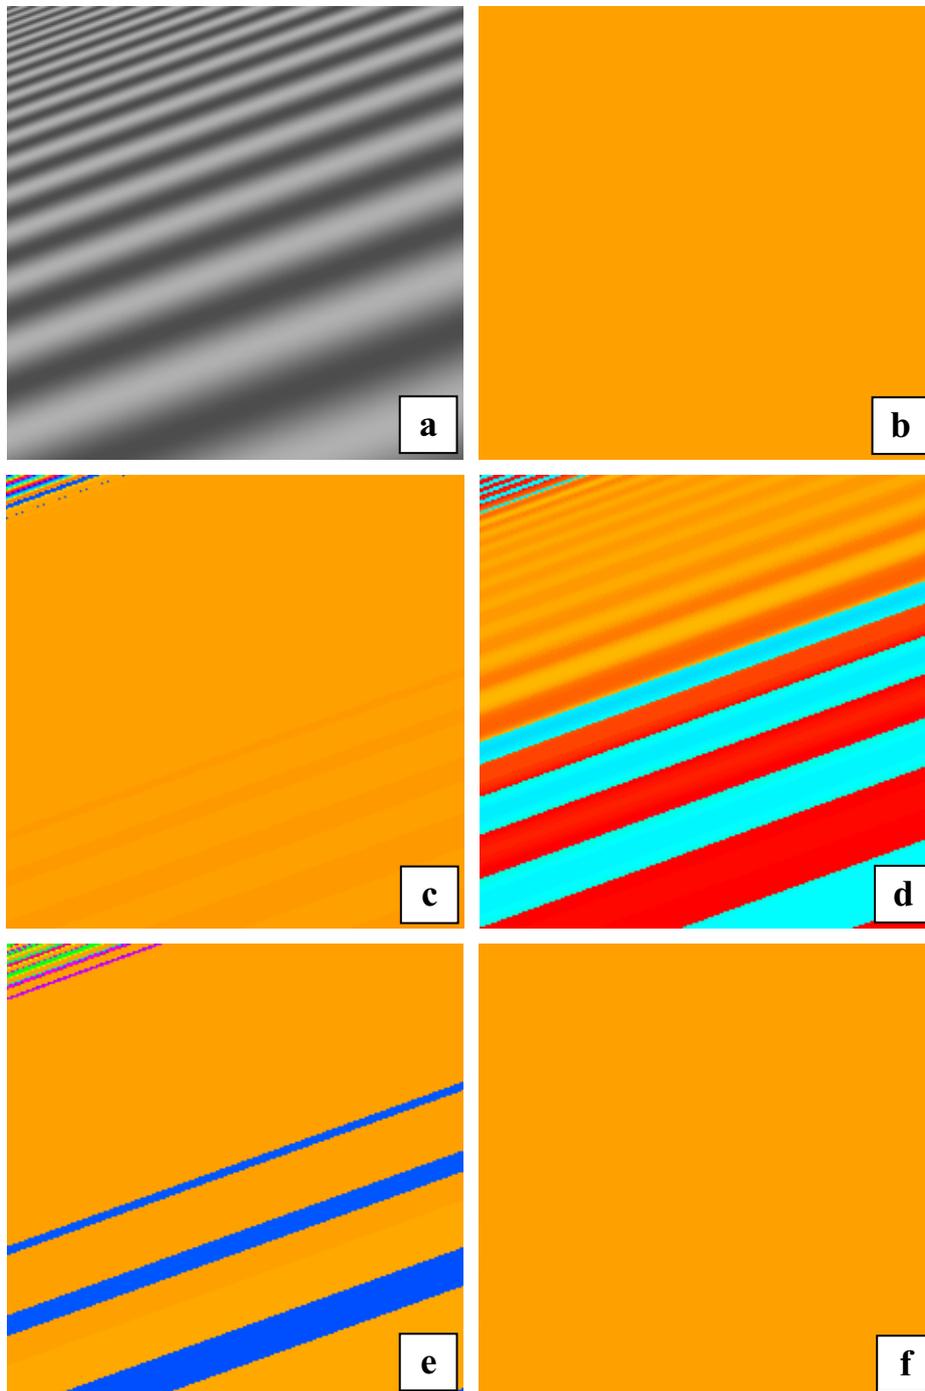
2.6.5 Robustesse au choix des paramètres

Nous avons remarqué en partie 2.6.2 que les filtres de Gabor pouvaient être sensibles au réglage de leur paramètre de fréquence. Nous avons également constaté en partie 2.6.3 que les filtres steerable étaient capables de donner des estimations de l'orientation fortement biaisées si leur échelle n'était pas adaptée à l'échelle des structures présentes dans l'image.

Nous vérifions cette hypothèse par l'estimation de l'orientation sur une texture non bruitée, de profil sinusoïdal modulé en fréquence, dont l'orientation est constante sur toute l'image.

La période du profil dans l'image varie de 3 à 30 pixels. La figure 2.32 présente tout d'abord les résultats sous la forme de cartes d'orientation obtenues pour une orientation donnée. La table 2.6 indique les différentes valeurs d'EAM obtenues, moyennées pour différentes valeurs d'orientation de l'image étudiée.

Les opérateurs utilisés ont pour paramètres : $E=10$ pixels, $T_\theta = 1^\circ$, $F=1$. Les filtres de Gabor sont réglés sur une période $T_0 = 10$ pixels.



*Fig. 2.32 Image étudiée (a) et orientation théorique (b)
 Cartes d'orientation obtenues par : les filtres steerable E2 (c), les filtres steerable E4 (d),
 les filtres de Gabor (e), l'opérateur IRON (f)*

Pour l'opérateur IRON, les résultats obtenus par l'attribut variationnel ou l'attribut de variance sont identiques (Fig. 2.32-f).

L'EAM est calculé pour 180 images dont les orientations sont réparties uniformément entre 0° et 90° .

Opérateur	Gabor	Steerable E2	Steerable E4	Variationnelle	Variance
EAM	12.9	1.68	24.0	0.250	0.250

Tab. 2.6 Erreur moyenne d'estimation sur une texture de période variable

Au vu des cartes d'orientation obtenues, nous remarquons un comportement similaire pour les filtres de Gabor et les filtres steerable : ces opérateurs n'estiment correctement l'orientation que dans une plage de fréquences limitée. Ceci s'interprète simplement pour les filtres de Gabor par la forme des masques fréquentiels des filtres, centrés sur une fréquence particulière.

Les filtres de Gabor et des filtres steerable présentant des similitudes dans leur principe et leurs comportements sont comparables : ils ne détectent pas l'orientation des variations du signal pour une période de l'image trop petite ou trop grande par rapport à la taille du masque utilisé.

Pour un noyau de filtres steerable donné, le choix de l'échelle ne dépend donc pas que des variations d'orientation de l'image mais aussi de la taille des structures présentes dans l'image. Pour les filtres de Gabor, il est possible de régler la période du filtre indépendamment de la taille du masque.

En ce qui concerne l'opérateur IRON, les variations de la période locale n'ont pas d'influence sur l'estimation de l'orientation.

Rappelons toutefois que dans le cas de l'estimation de l'orientation sur une image bruitée, si l'échelle d'analyse est très inférieure à l'échelle des structures déterminant l'orientation de l'image, la dynamique du signal dans le voisinage étudié sera réduite et donc le rapport signal sur bruit dans le voisinage étudié sera plus faible.

2.6.6 Sélectivité angulaire des opérateurs symétriques

Nous effectuons un test identique à celui mené au paragraphe 2.5.2 [Che 98] pour étudier la sélectivité angulaire des méthodes classiques.

Pour plusieurs échelles d'analyse, nous déterminons les tracés de $\Delta\theta_0$ et $\Delta\theta_{\min}$ pour les filtres de Gabor puis pour les filtres steerable E2 et E4. Les courbes sont obtenues pour les échelles $E \in \{5, 15, 45\}$. Les courbes de la mesure de $\Delta\theta_{50\%}$ sont disponibles en Annexe H, ainsi qu'un comparatif de l'allure des réponses angulaires pour les différentes méthodes.

Enfin, les meilleures valeurs possibles pour $\Delta\theta_{\min}$ et $\Delta\theta_0$ pour ces méthodes sont reportées dans les tables 2.7 et 2.8.

Filtres de Gabor

Sur les courbes suivantes (Fig. 2.33, Fig. 2.34 et Fig. 2.35), $\Delta\theta_{\min}$ apparaît en trait continu et $\Delta\theta_0$ apparaît en traits pointillés.

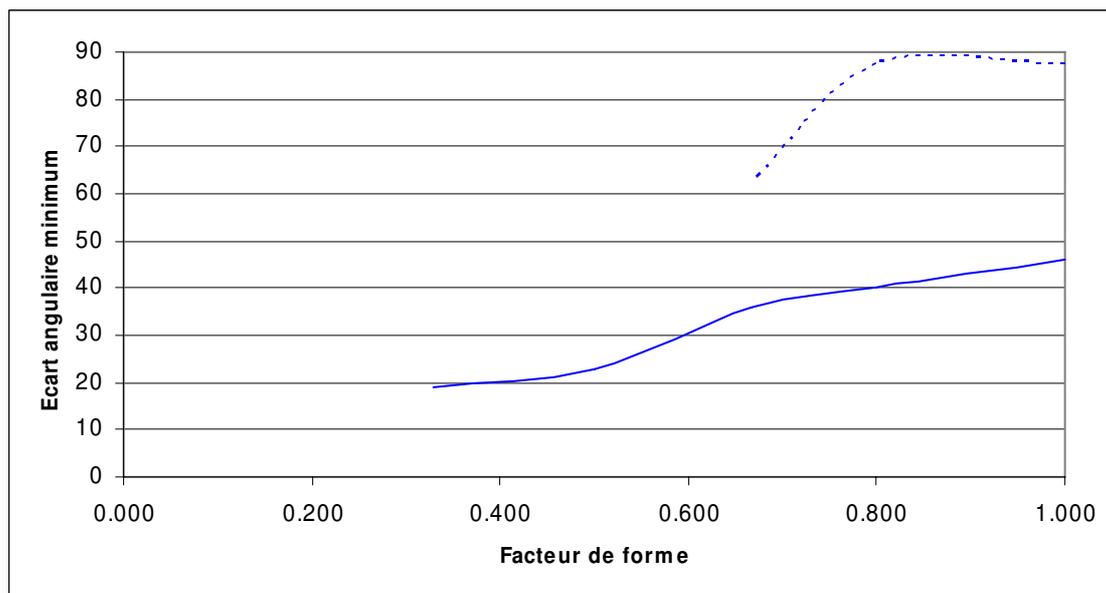


Fig. 2.33 Filtres de Gabor : écarts angulaires minimaux en fonction de F ($E=5$)
 ($\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

Les filtres de Gabor éprouvent des difficultés à distinguer deux orientations proches l'une de l'autre à petite échelle ($E=5$).

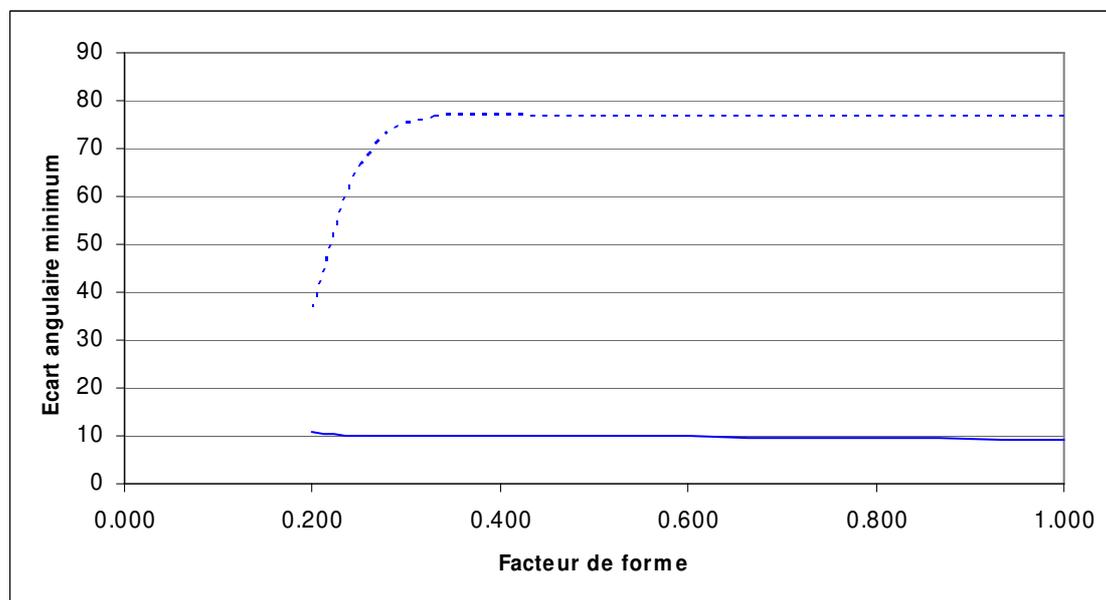


Fig. 2.34 Filtres de Gabor : écarts angulaires minimaux en fonction de F ($E=15$)
 ($\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

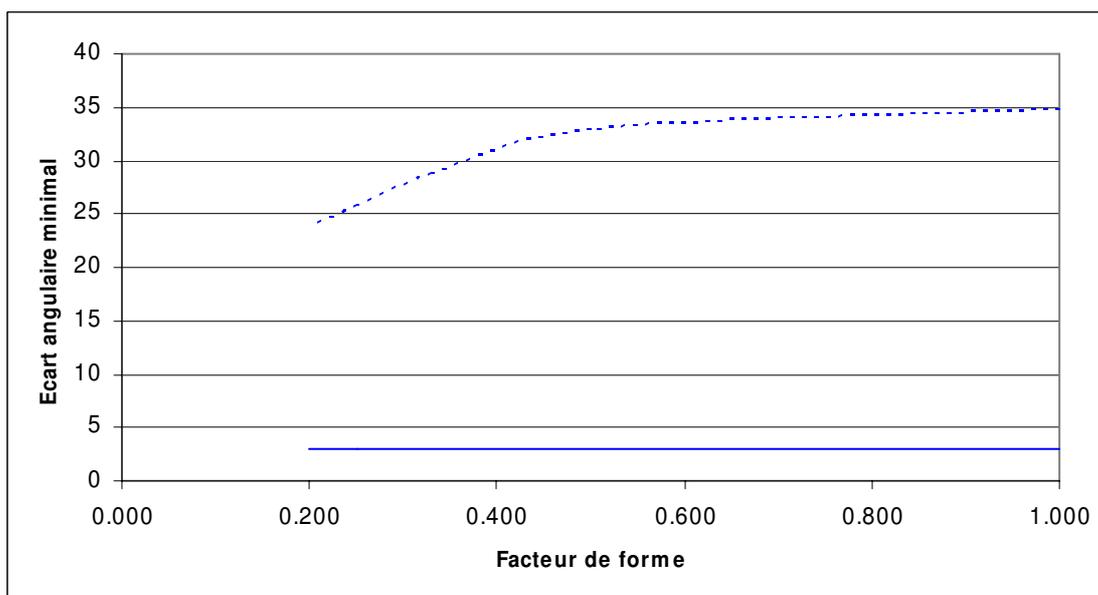


Fig. 2.35 Filtres de Gabor : écarts angulaires minimaux en fonction de F (E=45)
 ($\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

Par l'étude des courbes de $\Delta\theta_{\min}$ nous remarquons également que pour les autres échelles d'analyse, la sélectivité du filtre ne dépend quasiment pas du facteur de forme des filtres.

Il apparaît en effet que la sélectivité angulaire ne dépend que de l'échelle des filtres utilisés. En effet, un filtre très sélectif est caractérisé dans le domaine fréquentiel par une ouverture σ_φ très faible. Dans le domaine spatial, cette condition correspond à une ouverture σ_M très grande.

	E=5	E=15	E=45
$\Delta\theta_{\min}$	19°	9°	3°
$\Delta\theta_0$	63°	37°	24°

Tab. 2.7 Meilleures valeurs de $\Delta\theta_{\min}$ et $\Delta\theta_0$ obtenues à une échelle E donnée (filtres de Gabor)

L'expérimentation décrite dans [Chen 98] met en œuvre de filtres de variance σ constante. La variation du paramètre d'allongement λ (et donc du facteur de forme) correspond alors à un changement de l'échelle d'analyse E.

Ainsi, alors que la sélectivité de l'opérateur IRON dépend de l'épaisseur du réseau, la sélectivité angulaire des filtres de Gabor dépend de la longueur radiale des filtres.

Filtres steerable

Sur les courbes des écarts angulaires minimaux pour les filtres steerable (Fig. 2.36, Fig. 2.37 et Fig. 2.38), les tracés de $\Delta\theta_{\min}$ apparaissent en trait continu, et les tracés de $\Delta\theta_0$ apparaissent en traits pointillés.

Les courbes concernant les filtres steerable E2 sont représentées par les traits bleus fins. Les courbes relatives aux filtres steerable E4 sont représentées par les traits rouges épais.

A une échelle identique, les filtres steerable E4 sont en général plus sélectifs que les filtres E2. L'observation des courbes de $\Delta\theta_{\min}$ et $\Delta\theta_0$, nous montre que pour des facteurs de forme proches de 1, les filtres E4 fournissent des mesures alors que les filtres E2 ne distinguent plus les deux orientations.

A l'opposé, les filtres E2 peuvent estimer les orientations pour des facteurs de forme plus proches de 0 que pour les filtres E4.

Ceci peut se rapporter à la sensibilité au réglage de leur taille de support par rapport à la taille des structures de l'image (paragraphe 2.6.5).

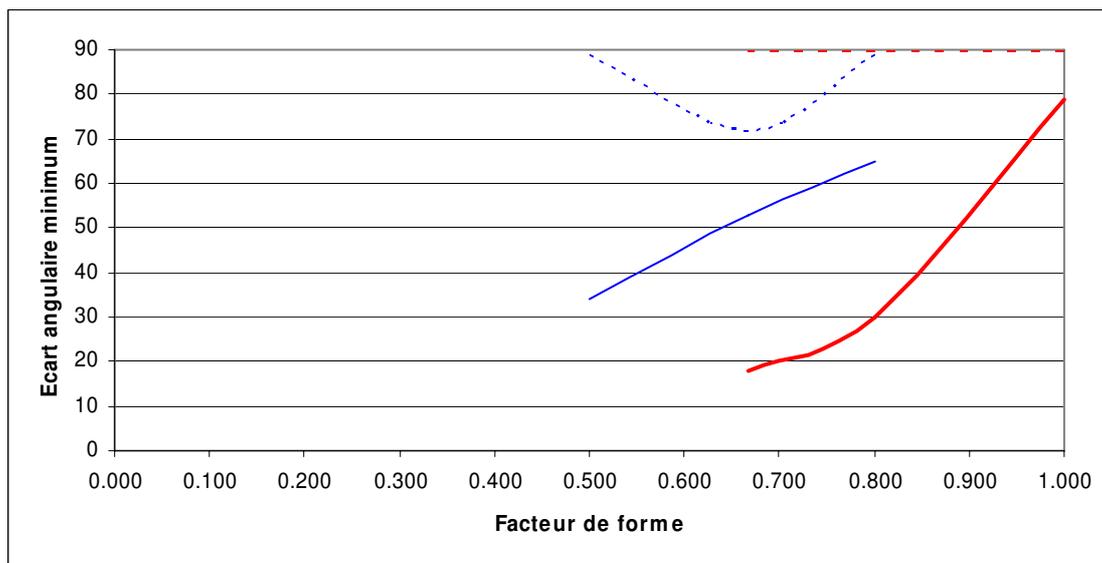


Fig. 2.36 Filtres steerable : écarts angulaires minimaux en fonction de F ($E=5$)
(E2 : trait fin, E4 : trait épais, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

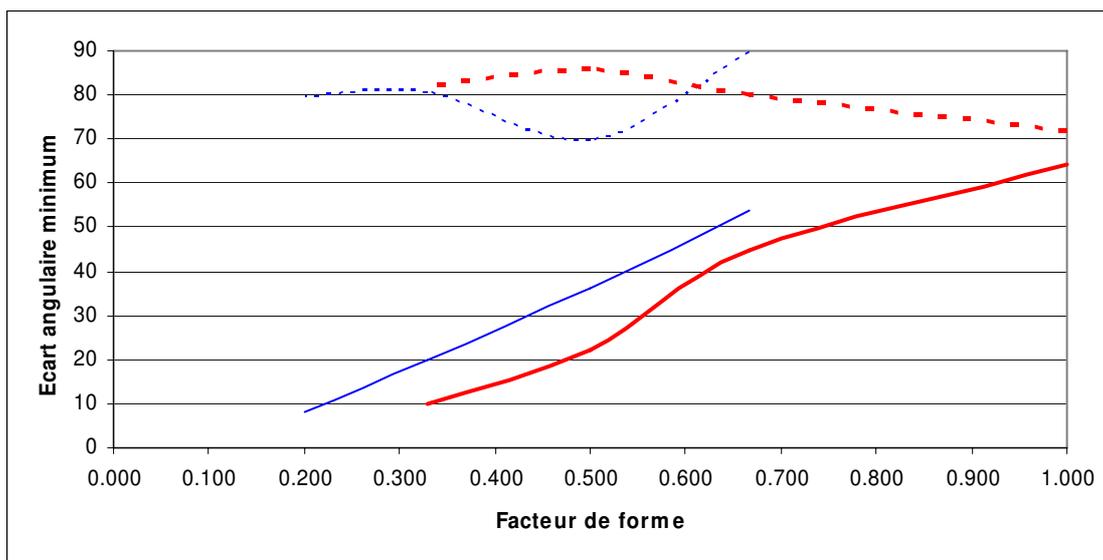


Fig. 2.37 Filtres steerable : écarts angulaires minimaux en fonction de F ($E=15$)
(E2 : trait fin, E4 : trait épais, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

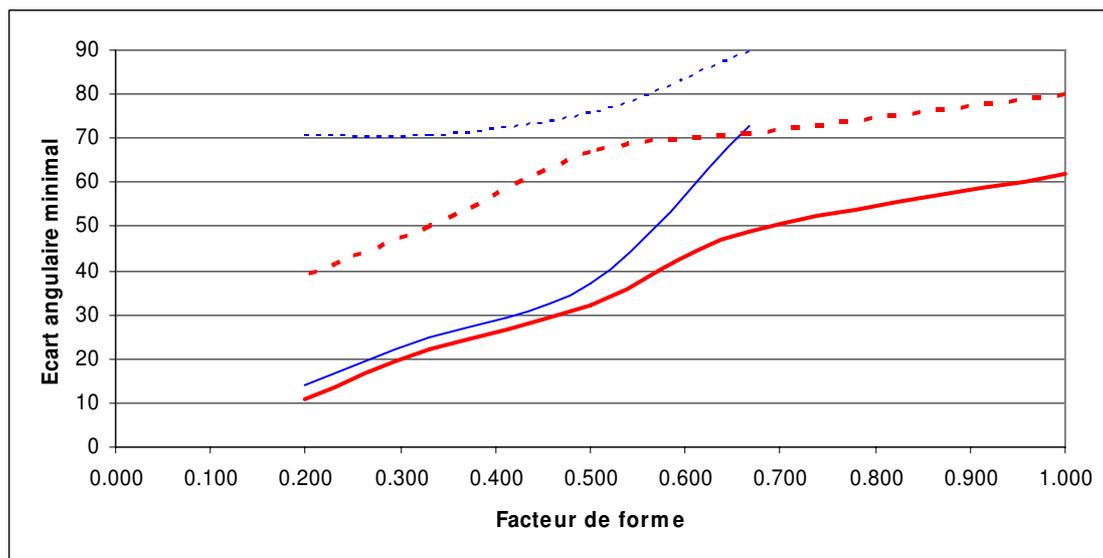


Fig. 2.38 Filtres steerable : écarts angulaires minimaux en fonction de F ($E=45$) ($E2$: trait fin, $E4$: trait épais, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

	$E=5$		$E=15$		$E=45$	
	$E2$	$E4$	$E2$	$E4$	$E2$	$E4$
$\Delta\theta_{\min}$	34°	18°	8°	10°	14°	11°
$\Delta\theta_0$	72°	90°	70°	72°	71°	39°

Tab. 2.8 Meilleures valeurs de $\Delta\theta_{\min}$ et $\Delta\theta_0$ obtenues à une échelle E donnée (filtres steerable $E2$ et $E4$)

Bilan sur la sélectivité angulaire

Tous filtres confondus, les meilleures performances sont récapitulées pour les différentes échelles d'analyse dans le tableau suivant :

	$E=5$	$E=15$	$E=45$
$\Delta\theta_{\min}$	4° IRON Variationnelle 1×11	4° IRON Variationnelle 3×31	3° Gabor (F indifférent)
$\Delta\theta_0$	34° IRON Variance 3×11	5° IRON Variationnelle 3×31	7° IRON Variationnelle 7×41

Tab. 2.9 Meilleures valeurs de $\Delta\theta_{\min}$ et $\Delta\theta_0$ obtenues tous opérateurs confondus

A petite et moyenne échelle (jusqu'à $E=15$), la meilleure sélectivité angulaire (avec ou sans biais) est obtenue par l'opérateur IRON. Pour l'échelle $E=45$, les filtres de Gabor offrent une meilleure sélectivité en ce qui concerne $\Delta\theta_{\min}$, mais de 1° seulement, et au prix d'une erreur d'estimation plus importante (3° d'erreur pour chaque orientation au lieu de 1° pour l'opérateur IRON).

Ainsi, quelle que soit l'échelle d'analyse E et contrairement aux autres méthodes d'estimation testées, l'opérateur IRON symétrique présente une bonne sélectivité angulaire.

De plus, le biais d'estimation de ces orientations obtenu grâce à l'opérateur IRON est plus faible que pour les autres méthodes.

2.6.7 Sélectivité angulaire des opérateurs asymétriques

Les opérateurs asymétriques permettent d'estimer l'orientation locale quand celle-ci n'est pas une donnée définie modulo π ou modulo 2π .

Nous comparons en termes de sélectivité angulaire la version asymétrique de l'opérateur IRON aux filtres asymétriques wedge steerable. Cette comparaison se fait par les valeurs $\Delta\theta_{\min}$ (écart angulaire minimal nécessaire pour discerner les deux orientations) et $\Delta\theta_0$ (écart minimal pour que l'estimation des deux orientations soit sans biais) obtenues pour différents jeux de paramètres.

La sélectivité des filtres wedge steerable dépend du nombre de filtres de base employés. Nous procédons à l'estimation des orientations pour des échelles $E \in \{5, 15, 45\}$, et pour un nombre de filtres de base $N_w = \{5, 10, 20\}$.

L'opérateur IRON asymétrique utilisant la variationnelle comme attribut est calculé pour des échelles $E \in \{5, 15, 45\}$ et pour divers facteurs de forme F .

L'image de test est constituée de deux segments de droite de profil gaussiens (Fig. 2.39).

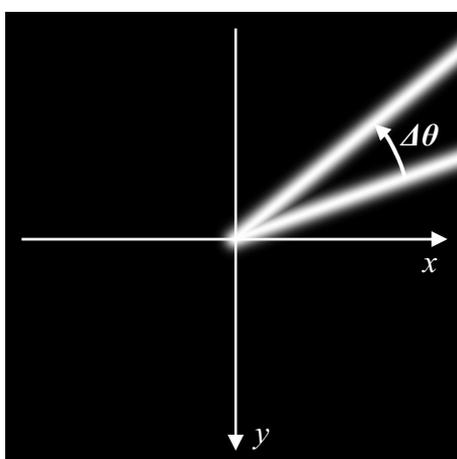


Fig. 2.39 Deux traits gaussiens (asymétrique)

Les courbes suivantes (Fig. 2.40, Fig. 2.41 et Fig. 2.42) représentent les valeurs de $\Delta\theta_{\min}$ (trait continu) et $\Delta\theta_0$ (pointillés) obtenues avec les filtres wedge steerable pour les échelles d'analyse sélectionnées.

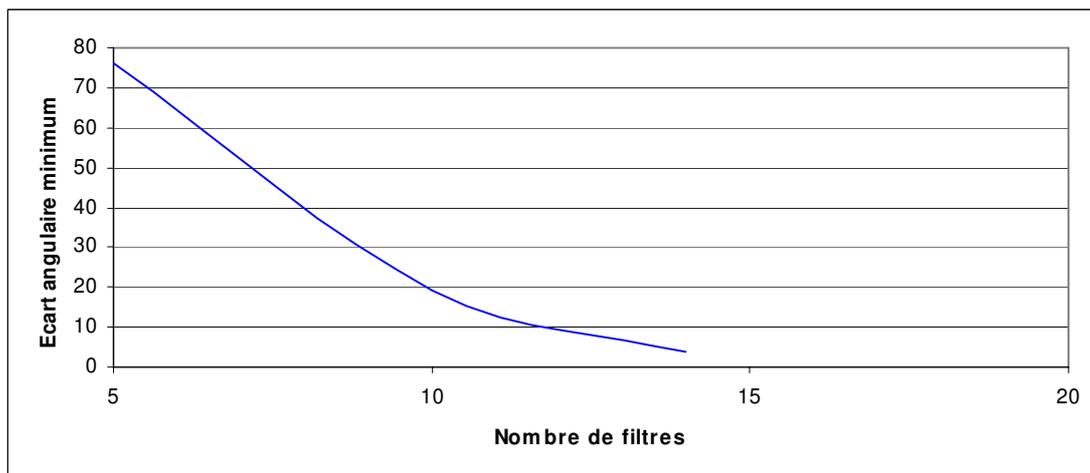


Fig. 2.40 Filtres wedge steerable : écarts angulaires minimaux en fonction du nombre de filtres de base ($E=5$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

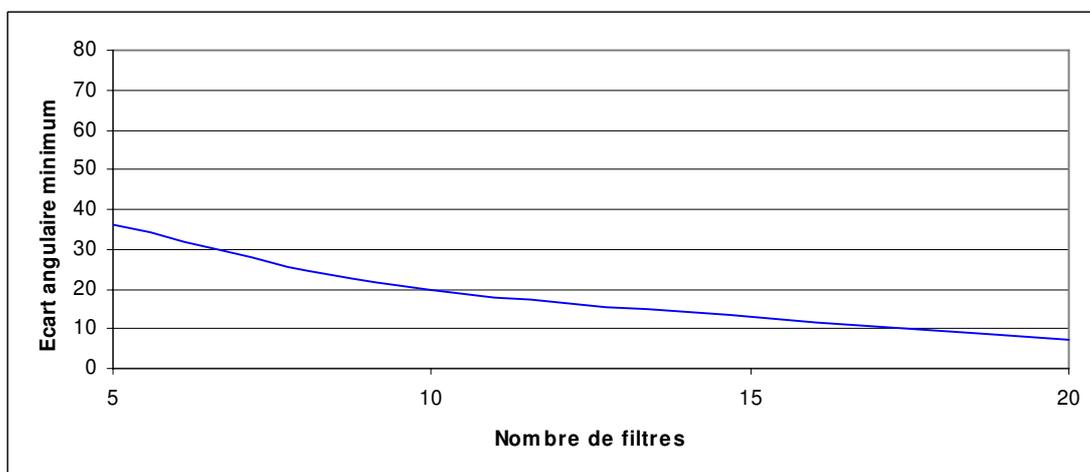


Fig. 2.41 Filtres wedge steerable : écarts angulaires minimaux en fonction du nombre de filtres de base ($E=15$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

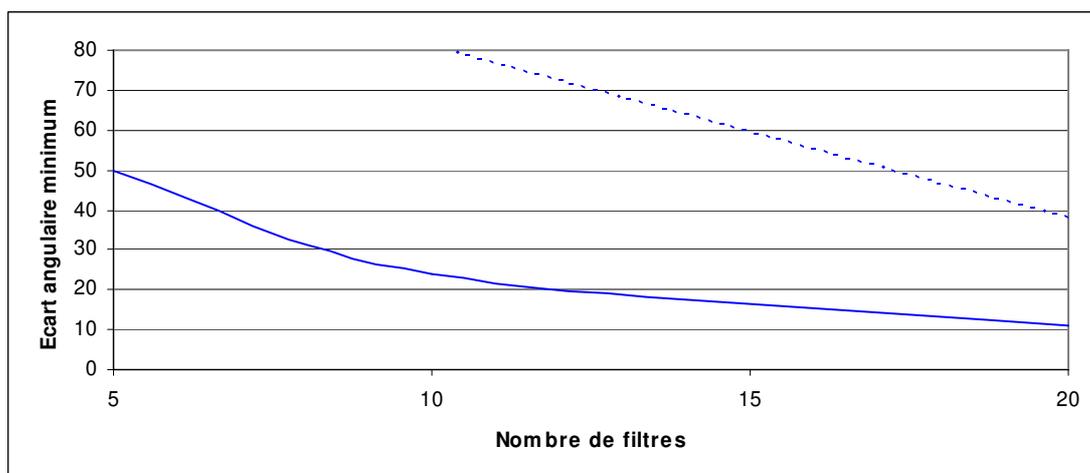


Fig. 2.42 Filtres wedge steerable : écarts angulaires minimaux en fonction du nombre de filtres de base ($E=45$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

Nous pouvons observer que les filtres wedge steerable deviennent plus précis lorsque l'échelle E augmente. Cependant, la meilleure sélectivité obtenue à une échelle donnée diminue quand l'échelle augmente.

Les orientations estimées sont très biaisées lorsque l'échelle E est faible, avec des erreurs d'estimation pouvant dépasser 15° . Ce phénomène peut être expliqué par le fait que le filtre semble alors détecter davantage les orientations des contours que celles des lignes.

Il faut garder à l'esprit qu'à une échelle d'analyse $E = 5$ et pour un tel opérateur asymétrique, le masque de convolution du filtre comporte peu de valeurs significatives.

Les courbes des figures Fig. 2.43, Fig. 2.44 et Fig. 2.45 présentent les résultats obtenus avec l'opérateur IRON asymétrique, utilisant la variationnelle comme attribut. Les courbes en trait continu représentent $\Delta\theta_{\min}$, les courbes en pointillés représentent $\Delta\theta_0$.

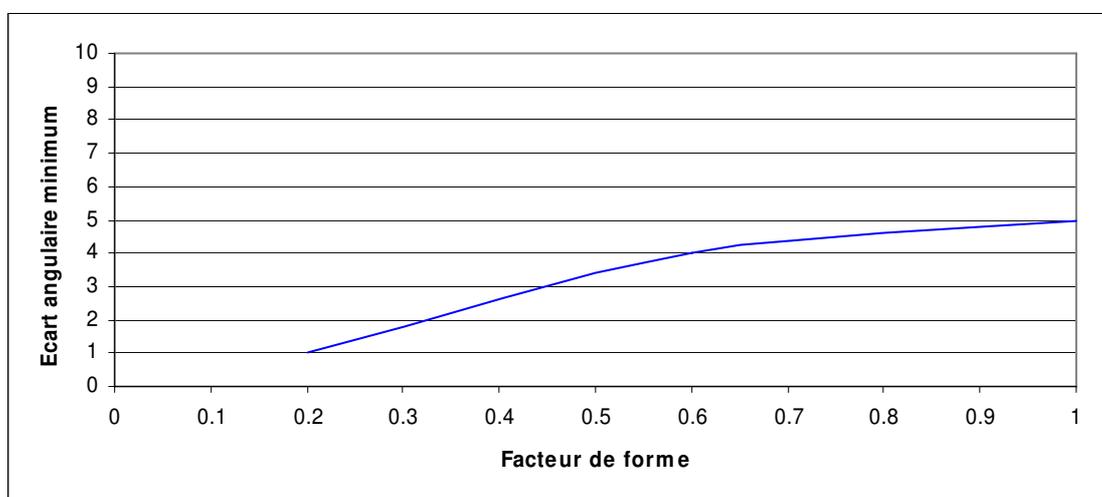


Fig. 2.43 IRON variationnelle asymétrique : écarts angulaires minimaux en fonction du facteur de forme F ($E=5$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

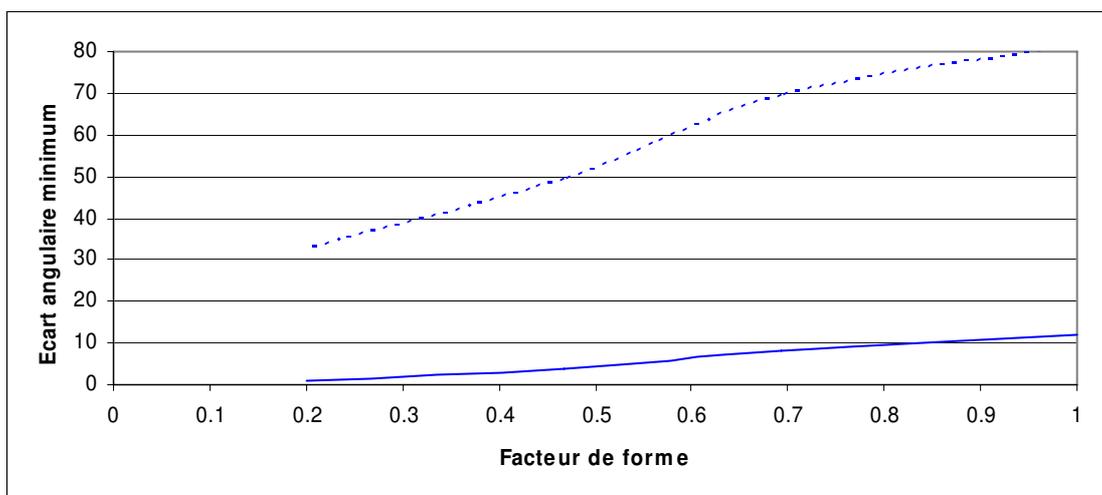


Fig. 2.44 IRON variationnelle asymétrique : écarts angulaires minimaux en fonction du facteur de forme F ($E=15$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

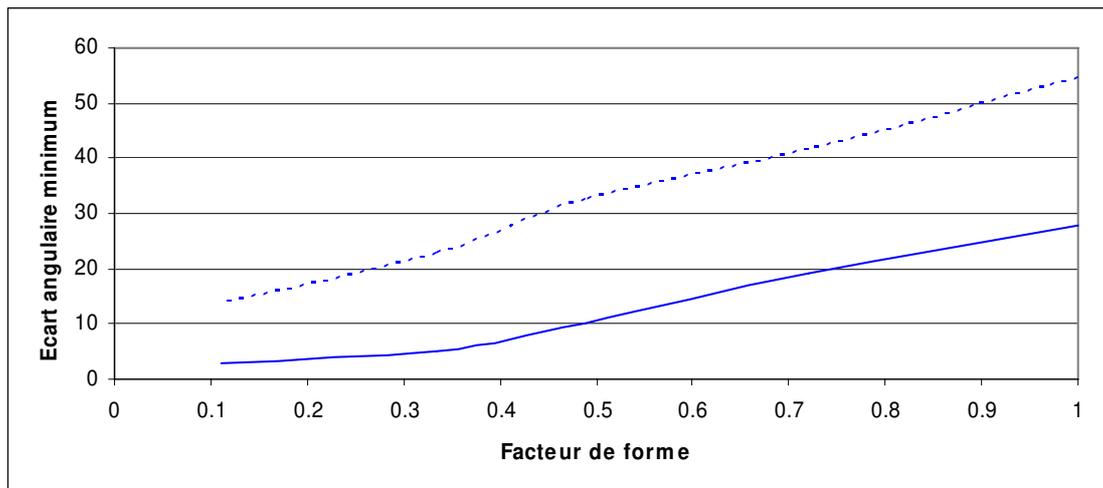


Fig. 2.45 IRON variationnelle asymétrique : écarts angulaires minimaux en fonction du facteur de forme F ($E=45$, $\Delta\theta_{\min}$: trait continu, $\Delta\theta_0$: traits pointillés)

Comme pour les filtres wedge steerable, nous remarquons que la précision augmente avec l'échelle d'analyse.

Pour une même échelle d'estimation, l'opérateur IRON se révèle cependant plus sélectif. De plus les erreurs d'estimation commises à petite échelle par l'opérateur IRON sont plus faibles que pour les filtres wedge steerable et ne dépassent pas 5° dans le pire des cas.

2.6.8 Coûts calculatoires

Afin de comparer les coûts calculatoires, nous considérons une image I carrée, de dimensions $D_I \times D_I$. Nous comparons les coûts calculatoires des opérateurs symétriques en prenant un pas angulaire d'échantillonnage des orientations T_θ , un facteur de forme F , et une échelle E identiques.

Dans le cas où $F=1$, le rapport entre la taille M des masques de convolution et les dimensions de notre réseau est : $M = 2E = \sqrt{L^2 + p^2} = L\sqrt{2}$

Afin de comparer plus simplement les méthodes, nous pouvons nous affranchir également de l'influence du pas angulaire en exprimant le coût calculatoire pour l'étude d'une seule orientation sur toute l'image I .

Pour les filtres de Gabor, ce coût est : $(2M^2 \cdot (Mult + Add)) \cdot D_I^2$

Pour les filtres steerable, avec B le nombre de filtres de base utilisés, le coût calculatoire est : $\left(\frac{2T_\theta B}{\pi} M^2 \cdot (Mult + Add) \right) \cdot D_I^2$

Pour l'opérateur IRON utilisant la variationnelle comme attribut et une interpolation de type B-spline de degré 3, ce coût est : $(75Mult + 68.5Add) \cdot D_I^2$ (en supposant $D_I^2 \gg D_I$).

Dans les mêmes conditions, pour l'opérateur IRON utilisant l'attribut variance, ce coût est : $(80Mult + 69.5Add).D_I^2$

En supposant que les initialisations de chaque calcul récursif sont négligeables, le coût calculatoire de l'opérateur IRON ne fait apparaître que des termes indépendants de l'échelle d'analyse E .

Les filtres de Gabor ont un coût proportionnel au carré de la taille de leur support de calcul.

En procédant à la convolution de moins de filtres de base, les filtres steerable ont un coût divisé par un facteur $\frac{\pi}{T_\theta B}$ par rapport aux filtres de Gabor.

Afin de fournir un ordre de grandeur, voici un tableau récapitulatif des temps d'exécution moyens des différentes méthodes sur deux images de tailles différentes et pour deux échelles d'analyse (nous utilisons 15 filtres de base pour les filtres steerable, dans la pratique cette valeur peut varier en fonction du facteur de forme F et de la précision désirée).

Les simulations ont été réalisées sur un PC de bureau doté d'un processeur cadencé à 3.2GHz, et équipé de 1Go de mémoire vive.

	Image 1 (128×128)		Image 2 (256×256)	
	E=5	E=45	E=5	E=45
IRON Variationnelle	4.2s	4.4s	21.3s	21.5s
IRON Variance	4.4s	4.5s	22.0s	22.1s
Gabor	3.3s	41.9s	16.2s	830s
Steerable	0.8s	4.1s	3.5s	77s

Tab. 2.10 Temps d'exécution des différentes méthodes

La taille des images indiquée dans le tableau correspond à la taille des images à l'entrée du processus d'estimation de l'orientation. En raison des effets de bord, la taille de la carte d'orientation en sortie est plus petite, et donc les temps de calcul ne sont pas directement proportionnels à la taille indiquée.

Enfin nous pouvons constater que, comme prévu, le temps d'exécution de l'opérateur IRON ne dépend quasiment pas de la taille de l'opérateur. Ceci est lié au calcul récursif de l'attribut.

Notons toutefois que des implantations récursives existent aussi pour les filtres de Gabor, permettant d'obtenir une complexité proportionnelle au nombre D_I^2 de pixels de l'image, et indépendante de la taille du masque utilisé [You 00].

2.7 Conclusion

Nous avons développé un opérateur d'estimation de l'orientation en nous appuyant sur une nouvelle définition de l'orientation locale.

Grâce à une implantation rapide, nous appelons cette méthode utilisant un réseau orienté l'opérateur IRON (Isotropic and Recursive Oriented Network).

Le réglage de l'opérateur IRON est simple : les seuls paramètres que l'utilisateur doit régler concernent la géométrie du réseau et le choix de l'attribut calculé sur le réseau. L'influence de chacun de ces paramètres est connue et le choix des paramètres dépend donc uniquement de l'application envisagée.

A travers nos expérimentations, nous avons pu vérifier que l'opérateur IRON répond aux objectifs et aux contraintes que nous nous étions fixés.

Nous pouvons noter en particulier que l'opérateur IRON présente un biais d'estimation nul sur une image non bruitée, ainsi qu'une bonne immunité au bruit.

De plus il a une meilleure sélectivité angulaire que les autres méthodes d'estimation de l'orientation.

L'opérateur IRON n'est pas sensible à la période locale de l'image et il fonctionne aussi bien à très petite échelle qu'à très grande échelle.

Enfin, le coût calculatoire de notre opérateur est suffisamment faible pour envisager son implantation dans des chaînes de traitement de données.

Ces propriétés font donc de l'opérateur IRON une alternative avantageuse aux autres méthodes d'estimation de l'orientation.

Chapitre 3

Adaptation de l'opérateur IRON à l'image

3.1 Introduction

La procédure d'estimation de l'orientation que nous avons présentée au chapitre 2 met en oeuvre deux types de paramètres. Les premiers paramètres définissent la géométrie de l'opérateur IRON. Le deuxième correspond au choix de la mesure d'homogénéité calculée sur le réseau orienté.

Alors que le choix des paramètres géométriques est comparable à celui qui est effectué pour d'autres méthodes d'estimation à base de bancs de filtres orientés, notre approche permet une plus grande liberté dans le choix de l'attribut calculé sur le réseau. Plus particulièrement, la fonction choisie peut être plus complexe qu'une simple convolution.

Par conséquent, la connaissance a priori de l'image nous permet de choisir de façon appropriée aussi bien les paramètres géométriques que l'attribut de réseau.

Ainsi, dans le contexte de la définition (4), où l'orientation locale est déterminée par la mesure d'un écart à un modèle, nous avons tout d'abord proposé, dans la perspective d'une image bruitée par un bruit blanc gaussien additif, un attribut fondée sur une estimation de la variance.

Nous avons par la suite proposé, une fonction d'homogénéité s'appuyant sur la variationnelle des niveaux de gris.

Dans ce chapitre, nous proposons des fonctions de réseau alternatives, adaptées à des conditions plus complexes d'estimation de l'orientation.

Dans le cas d'un bruit non gaussien, et plus particulièrement dans le cas d'un bruit impulsionnel, nous introduisons une fonction d'homogénéité fondée sur une mesure robuste de la variabilité des niveaux de gris.

Nous étendons également notre approche à certains cas où la définition (3) et par conséquent la définition (4) ne sont plus vérifiées. Nous étudierons en particulier le cas d'une image présentant des variations d'éclairage ou des modulations d'amplitude.

Enfin, en ce qui concerne le choix de la géométrie du réseau, nous proposons une stratégie pour déterminer l'échelle la plus appropriée à l'étude de l'image. En appliquant localement cette démarche, nous obtenons une version adaptative de l'opérateur IRON.

3.2 Bruit non gaussien

3.2.1 Problématique

Le bruit présent dans une image n'est pas obligatoirement gaussien, et ce bruit n'affecte pas nécessairement tous les pixels de l'image. C'est par exemple le cas du bruit impulsionnel.

Dans la plupart des modèles de bruit impulsionnel, les valeurs des pixels bruités sont remplacées par des valeurs choisies aléatoirement dans un intervalle donné [Abr 96].

Nous considérons ici deux modèles de bruit impulsionnel. Le premier modèle est un bruit impulsionnel à valeurs aléatoires binaires équiprobables, en l'occurrence le bruit poivre et sel, pour lequel les pixels bruités peuvent prendre les valeurs 0 ou 255 avec la même probabilité. Le deuxième modèle étudié est un bruit impulsionnel à valeurs uniformément réparties entre 0 et 255.

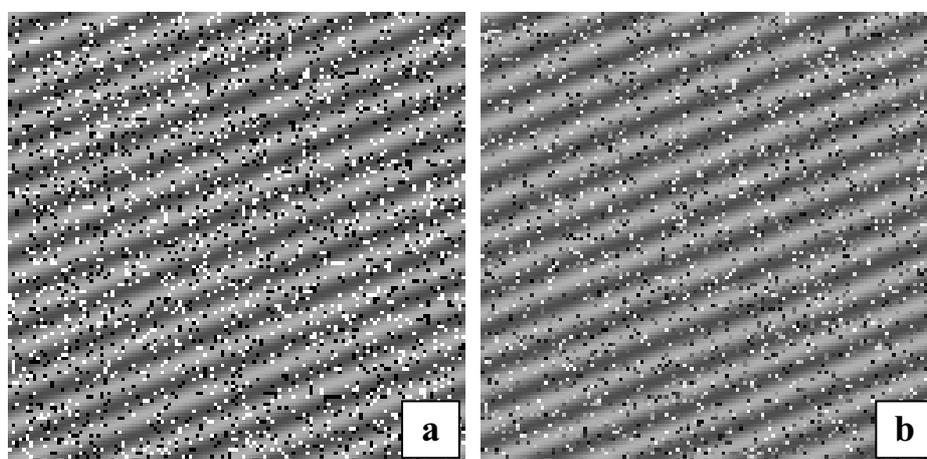


Fig. 3.1 Profil bruité par : a - un bruit poivre et sel (20%)
b - un bruit impulsionnel uniforme (20%)

La figure 3.1 présente une image orientée bruitée par de tels bruits impulsionnels.

Sur ces images, tous les pixels ne sont pas affectés par le bruit. L'opérateur IRON fondé sur la variance des niveaux de gris présente néanmoins une erreur d'estimation plus importante que dans le cas gaussien. Sur une image bruitée à 0dB par un bruit blanc gaussien et pour une échelle d'analyse $E = 5$ cette erreur, mesurée par l'Ecart Angulaire Moyen, vaut $EAM = 7.5^\circ$. Pour une image bruitée par un bruit poivre et sel au même RSB (ce qui correspond à un taux de pixels bruités de 7.5%) l'erreur moyenne d'estimation vaut alors $EAM = 9.2^\circ$.

Dans le cas de tels bruits impulsionnels, comme moins de pixels sont perturbés par le bruit, l'attribut fondé sur la variationnelle conduit à une estimation moins erronée que dans le cas gaussien. L'erreur vaut alors $EAM = 30.0^\circ$ dans le cas gaussien et $EAM = 10.3^\circ$ dans le cas d'un bruit poivre et sel.

Malgré la diminution de l'erreur obtenue avec la variationnelle, cette erreur reste plus importante que celle obtenue avec la variance.

Nous proposons dans ce qui suit un attribut peu sensible au bruit impulsionnel et qui délivre de meilleurs résultats que ceux obtenus par l'attribut variance.

3.2.2 Solution envisagée

Quel que soit le bruit perturbant l'image étudiée, nous pouvons choisir de mesurer l'écart de l'image au modèle de telle façon que cette mesure soit peu sensible au bruit. Ceci est possible grâce au perfectionnement de l'attribut d'homogénéité calculé sur le réseau.

Pour ce faire nous proposons un estimateur robuste fondé sur un calcul de médianes en remplacement des moyennes. Cet attribut consiste à calculer la médiane des écarts à la médiane de l'ensemble des niveaux de gris le long de chaque ligne du réseau. Il correspond à la Median Absolute Deviation (MAD), qui, dans le cas d'une variable aléatoire de distribution gaussienne, est proportionnelle à l'écart type :

$$MAD = 1.4826 \cdot \sigma \quad (3.1)$$

avec σ^2 la variance de la variable aléatoire gaussienne.

Considérons un réseau orienté d'angle θ , comportant L lignes et p points par ligne et pour lequel $v_{i,j,\theta}$ représente le niveau de gris du $i^{\text{ème}}$ point de la $j^{\text{ème}}$ ligne.

L'estimateur robuste pour la ligne j d'un tel réseau s'exprime par :

$$MAD_j(x, y, \theta) = \underset{i=1}{\overset{p}{M}} \left(v_{i,j,\theta} - \underset{k=1}{\overset{p}{M}} (v_{k,j,\theta}) \right) \quad (3.2)$$

La grandeur $\underset{i}{M}(x_i)$ représente la médiane des $\{x_i\}$.

Cet attribut d'homogénéité fondé sur des médianes, dont la valeur ne dépend pas des valeurs extrêmes du groupe de pixels étudiés, est peu sensible à un bruit perturbant fortement un faible nombre de pixels.

3.2.3 Résultats

Afin de vérifier la validité de cet attribut robuste d'homogénéité, nous effectuons des mesures d'orientation sur des images bruitées par du bruit impulsionnel.

Les images étudiées sont construites à partir d'un profil sinusoïdal de période $T = 10$ pixels, développé dans une direction θ donnée, ce qui correspond à notre modèle (Eq.1.2).

Nous calculons alors l'EAM obtenu pour plusieurs orientations d'images et pour plusieurs réalisations du bruit.

Les estimations de l'orientation sont réalisées pour différentes échelles d'analyse, et pour un facteur de forme unitaire ($F = 1$). Le pas d'échantillonnage de la réponse angulaire des opérateurs vaut $T_\theta = 1^\circ$.

Les méthodes d'estimation de l'orientation utilisées sont :

- attribut variationnel, variance et attribut robuste MAD.
- filtres steerable E2 et E4. Nous ne présentons pas les résultats obtenus avec ces filtres pour une échelle $E = 45$ pixels, car comme nous l'avons vu précédemment (chapitre 2.6.5) les filtres ne sont alors plus appropriés à l'estimation de l'orientation sur une telle image.
- filtres de Gabor.

Nous utilisons deux types de bruit impulsif : le bruit poivre et sel et le bruit impulsif uniforme. Les estimations de l'orientation sont effectuées pour différents pourcentages de pixels bruités.

Pour une image bruitée par un bruit poivre et sel, les valeurs d'erreur moyenne d'estimation de l'orientation sont reportées dans le tableau suivant (Tab. 3.1)

	E	5%	10%	20%	30%
Variationnelle	5	6.77	14.3	27.0	34.6
	15	3.01	9.21	18.2	28.0
	45	1.14	3.72	6.72	9.21
Variance	5	7.11	11.6	20.0	26.2
	15	1.07	1.48	2.17	4.21
	45	0.263	0.273	0.333	0.575
MAD	5	1.94	4.37	11.8	17.8
	15	0.302	0.541	1.09	1.52
	45	0.250	0.250	0.255	0.295
Steerable E2	5	5.54	9.74	17.7	24.6
	15	4.87	9.23	17.8	24.3
Steerable E4	5	18.7	28.7	37.8	40.5
	15	1.62	2.22	3.38	5.42
Gabor	5	11.3	18.6	28.2	34.0
	15	0.564	0.750	1.20	1.53
	45	0.259	0.270	0.275	0.295

Tab. 3.1 EAM obtenu sur une image bruitée par un bruit poivre et sel

Il convient également d'observer l'allure des cartes d'orientations obtenues grâce à ces opérateurs pour une échelle d'analyse $E = 15$ pixels (Fig. 3.3) sur une image orientée à $\theta = 20^\circ$ bruitée par un bruit poivre et sel (Fig. 3.2) :

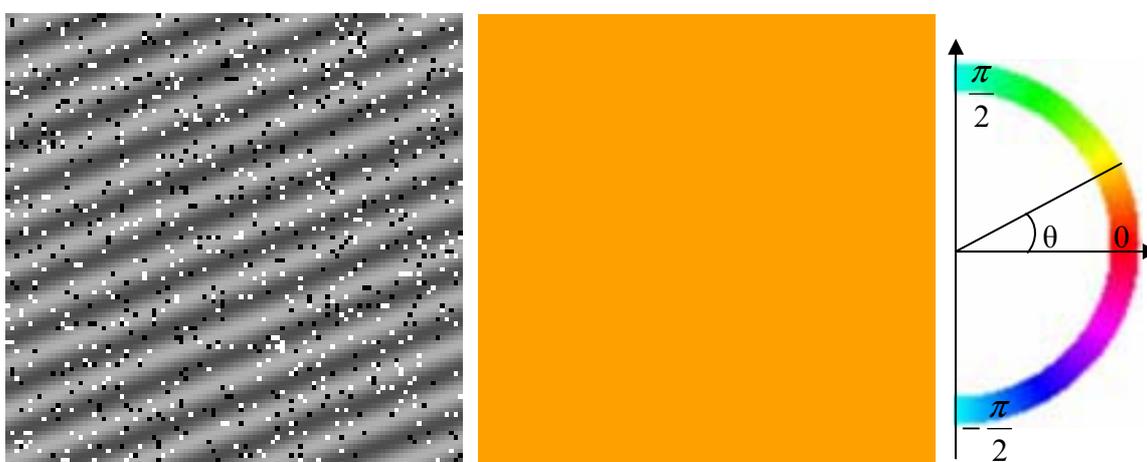


Fig. 3.2 Profil bruité par un bruit poivre et sel (10%), orientation théorique et palette d'orientation

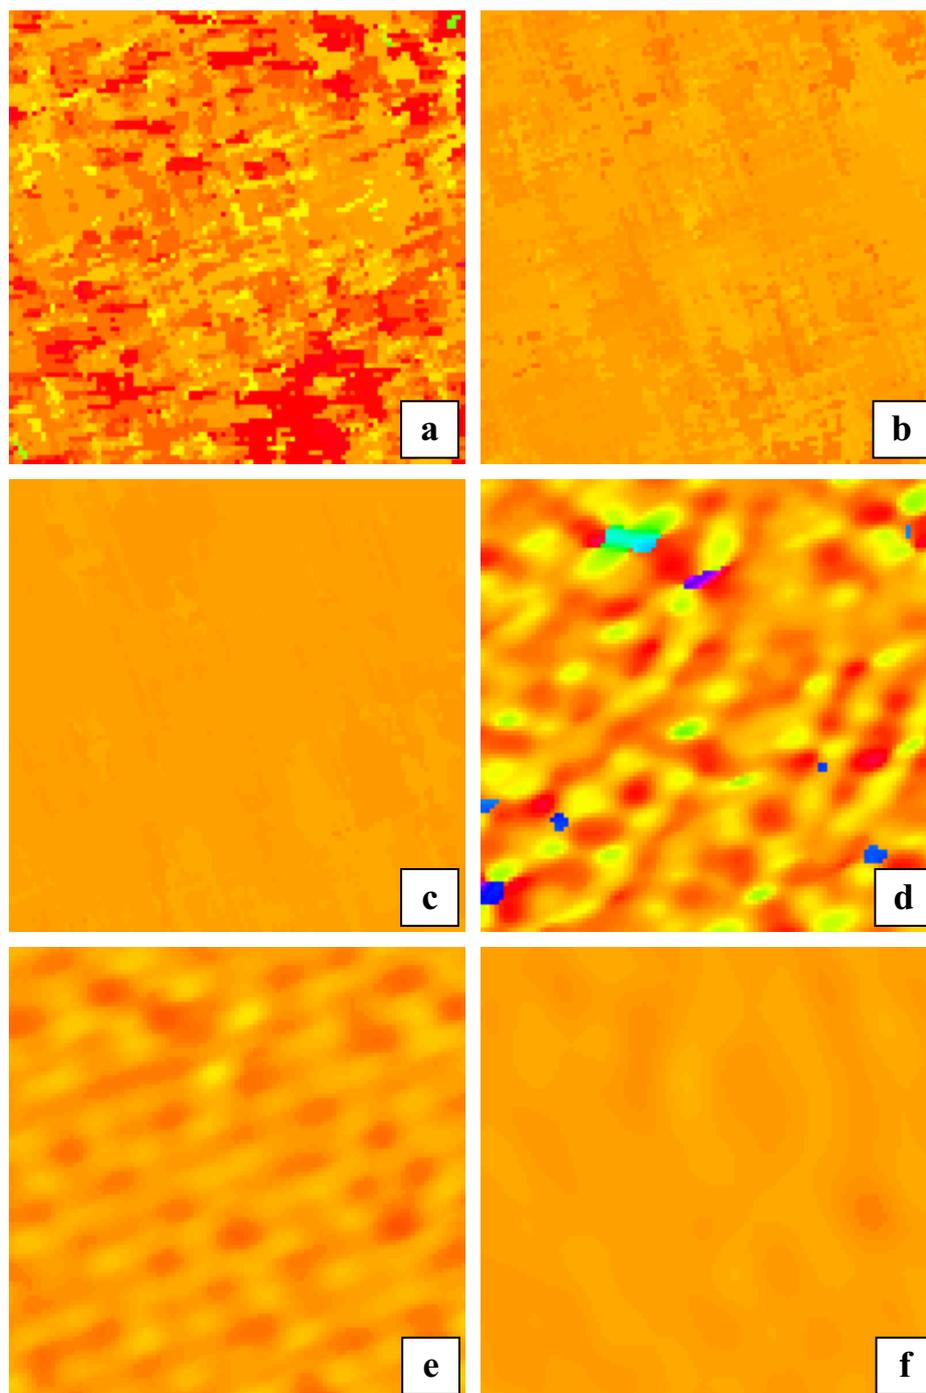


Fig. 3.3 Orientation estimée par la variationnelle (a), la variance (b), l'attribut MAD (c), les filtres steerable E2 (d), les filtres steerable E4 (e) et les filtres de Gabor (f)

Sur ces cartes d'orientation, nous pouvons percevoir que l'opérateur IRON fondé sur la variance, ou sur notre attribut robuste de variabilité ainsi que les filtres de Gabor sont moins sensibles à ce type de bruit que les filtres steerable ou l'opérateur fondé IRON sur la variationnelle.

Notons toutefois que les filtres de Gabor requièrent une connaissance a priori de l'image, à savoir la période texturale T , ce qui n'est pas le cas de notre opérateur.

Pour un bruit impulsionnel uniforme, les résultats suivants sont obtenus :

	E	5%	10%	20%	30%
Variationnelle	5	3.26	6.79	15.5	22.6
	15	1.29	3.29	9.20	13.6
	45	0.631	1.59	4.73	4.42
Variance	5	3.91	6.18	10.2	14.8
	15	0.778	0.912	1.37	1.67
	45	0.253	0.253	0.256	0.401
MAD	5	1.07	2.09	4.54	8.37
	15	0.255	0.323	0.600	0.851
	45	0.250	0.250	0.250	0.254
Steerable E2	5	2.78	4.68	8.79	12.9
	15	2.77	4.40	8.26	13.9
Steerable E4	5	11.0	17.9	28.3	33.6
	15	1.29	1.56	2.08	2.63
Gabor	5	5.53	9.71	16.85	23.4
	15	0.355	0.500	0.687	0.857
	45	0.250	0.250	0.251	0.264

Tab. 3.2 EAM obtenu sur une image bruitée par un bruit impulsionnel uniforme

Sur les tables 3.1 et 3.2, l'attribut robuste MAD donne des résultats meilleurs que les autres opérateurs, en particulier à petite échelle. Il n'y a que dans le cas d'une estimation à grande échelle que les filtres de Gabor font jeu égal avec cet opérateur.

L'attribut MAD est cependant moins approprié à l'estimation de l'orientation sur une image bruitée par un bruit affectant tous les pixels de l'image (par exemple un bruit blanc gaussien).

Nous comparons les performances de l'attribut MAD et de l'attribut variance sur une image perturbée par un bruit blanc gaussien :

	E	RSB = 20dB	RSB = 10dB	RSB = 5dB	RSB = 0dB
Variance	5	0.664	2.007	3.847	7.513
	15	0.253	0.335	0.555	0.987
	45	0.250	0.250	0.252	0.259
MAD	5	1.054	3.182	5.764	12.024
	15	0.265	0.561	1.005	1.672
	45	0.250	0.251	0.271	0.373

Tab. 3.3 EAM obtenu sur une image bruitée par un bruit blanc gaussien.

Sur une telle image, quelles que soient l'échelle E et la variance du bruit blanc gaussien, l'estimation obtenue grâce à l'attribut MAD présente une erreur plus grande que celle obtenue par la variance (Tab. 3.3).

Enfin, notons que l'attribut robuste MAD, fondé sur un calcul de médianes ne peut pas être calculé récursivement de manière simple et que par conséquent son coût calculatoire final dépend de la taille du réseau utilisé, et plus particulièrement de la longueur des lignes.

Pour une image 128×128 et pour un réseau d'échelle $E = 5$ pixels utilisant une spline d'ordre 3 comme interpolation, l'estimation de la carte des orientations nécessite 12.7s de temps de calcul contre 4.4s pour la variance.

Pour une échelle $E = 15$, ce temps passe à 34s pour l'opérateur robuste contre 4.5s pour la variance.

3.3 Image modulée en amplitude

3.3.1 Problématique

Étudions le cas d'une texture directionnelle I de profil h quelconque, modulée en amplitude.

La figure 3.4 présente une telle image, pour laquelle le profil h est sinusoïdal, modulé par une fonction g affine agissant dans la direction de l'image.

Sur une telle image, à cause de l'influence de la modulation d'amplitude, l'orientation des tangentes aux courbes de niveau ne correspond plus aux orientations recherchées. Nous pouvons constater ce phénomène plus facilement en observant la vue en niveaux de gris de cette image (Fig. 3.4).

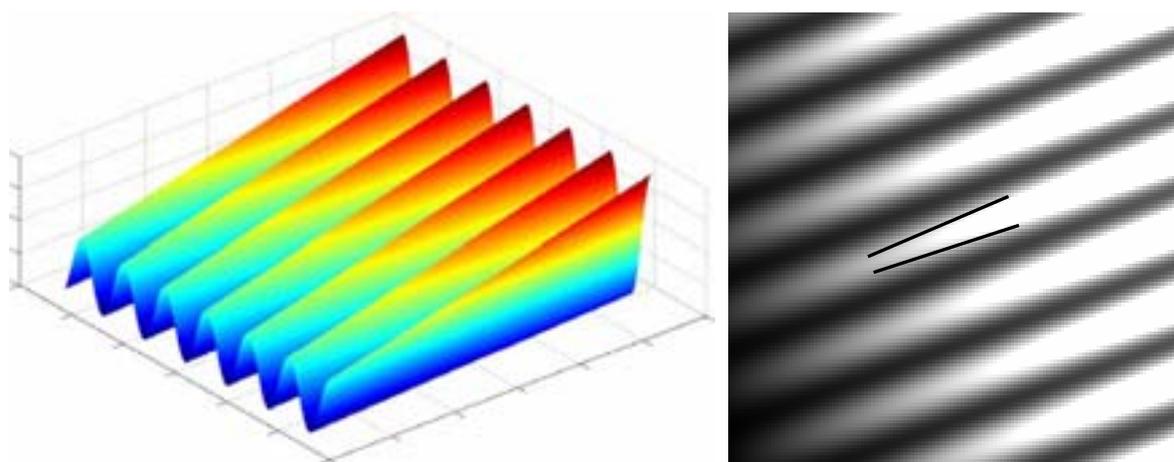


Fig. 3.4 Profil sinusoïdal modulé linéairement en amplitude et modification de l'orientation des lignes de niveau

Notons qu'une modulation d'amplitude parallèle à la texture n'apporterait aucune perturbation à l'orientation. Seul le profil h serait modifié.

A l'échelle locale, un opérateur fondé sur la définition surfacique de l'orientation (définition 4) conduit donc à une estimation biaisée des orientations. Ceci est vérifié par l'expérimentation (Fig. 3.5).

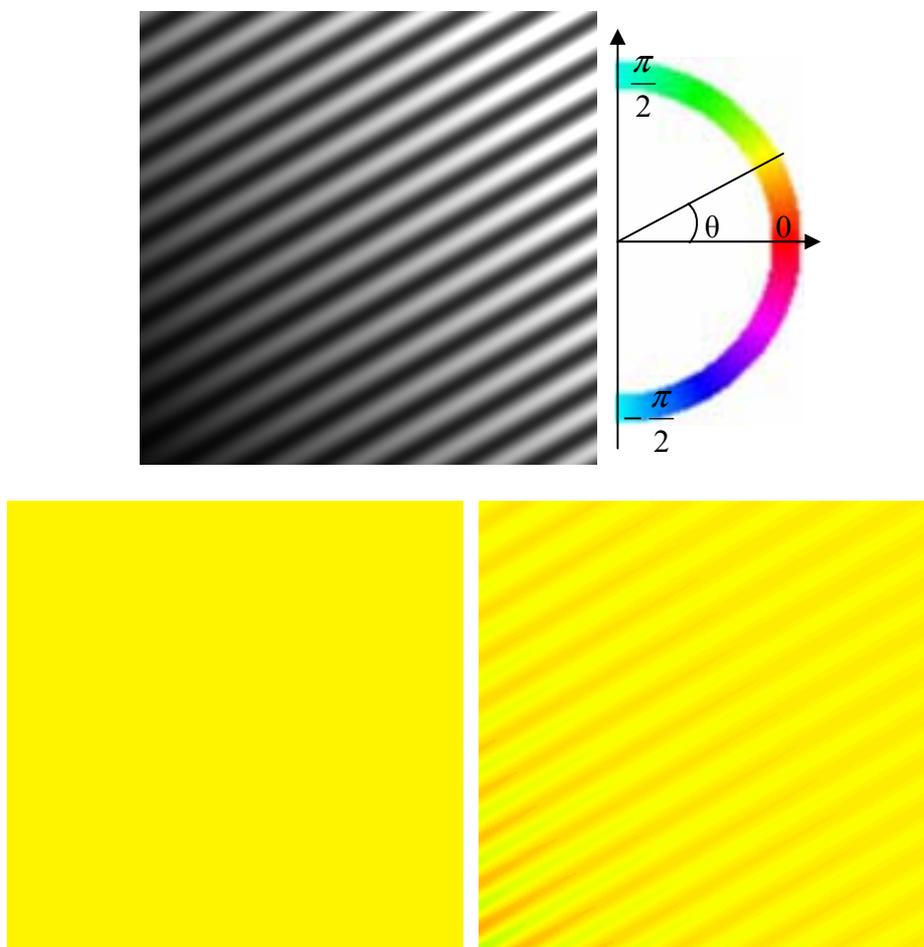


Fig. 3.5 Profil modulé en amplitude, palette d'orientation, orientation théorique et orientation estimée par IRON variance

A plus grande échelle, les perturbations dues à la modulation d'amplitude se compensent partiellement et l'estimation est donc moins sensible à cette modulation.

3.3.2 Solution envisagée

Afin de retrouver l'orientation initiale de la texture, nous souhaitons nous affranchir de la perturbation due à la modulation d'amplitude.

Notre étude s'effectue dans le repère orthonormé dont l'axe des abscisses \vec{i}_θ correspond à la direction de l'image (Fig. 3.6).

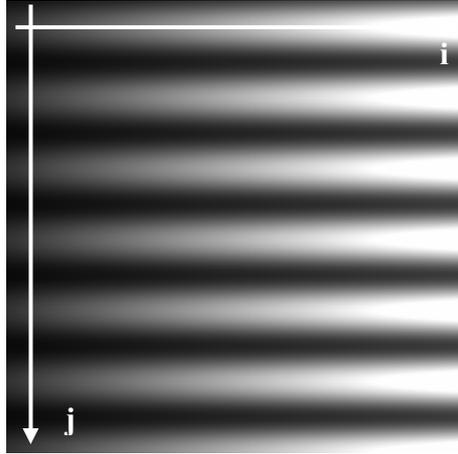


Fig. 3.6 Repère orthonormé placé sur l'image

Nous faisons l'hypothèse que l'image I peut être localement assimilée à un profil h quelconque modulé en amplitude par une fonction g agissant dans la direction de l'image.

Etant donné ce modèle, nous pouvons utiliser la même démarche qu'utilisée au chapitre 2 : nous allons donc chercher la ou les orientations pour lesquelles l'image correspond le mieux à ce modèle.

Ceci revient à chercher l'orientation θ qui minimise, sur un réseau donné, l'écart ε entre l'image I dont l'intensité est donnée par $f(i, j)$ et son modèle $h(j).g(i)$:

$$\varepsilon(\theta) = \left\| h(j).g(i) - f(i, j) \right\|_{(i,j) \in V(\theta)} \quad (3.3)$$

Nous devons donc estimer conjointement $h(j)$ et $g(i)$ afin de déterminer l'orientation correspondant à la meilleure adéquation entre le modèle et l'image.

3.3.3 Résolution

En choisissant d'évaluer l'écart quadratique, l'équation (3.3) revient à minimiser :

$$\varepsilon(\theta) = \sum_{(i,j) \in V(\theta)} (h(j).g(i) - f(i, j))^2 \quad (3.4)$$

Nous considérons ici que la modulation d'amplitude est lente par rapport aux variations de la fonction de profil h et peut être localement considérée comme une modulation affine de la forme $g(i) = 1 + \alpha.i$. Ceci correspond typiquement à une variation d'éclairage sur une scène naturelle.

La fenêtre d'observation de l'image I pour la détermination de g et h correspond aux dimensions D_L et D_R du réseau qui comporte $D_L = L$ lignes et $D_R = p$ points par ligne.

$$\varepsilon(\theta) = \sum_{i=1}^p \sum_{j=1}^L (h(j).g(i) - f(i, j))^2 = \sum_{i=1}^p \sum_{j=1}^L (h(j)(1 + \alpha.i) - f(i, j))^2 \quad (3.5)$$

Lorsque le minimum de ε est atteint, ses dérivées par rapport aux grandeurs h et α sont nulles :

$$\frac{\partial \varepsilon}{\partial h} = 2 \sum_{i=1}^p \sum_{j=1}^L (1 + \alpha \cdot i) \cdot (h(j)(1 + \alpha \cdot i) - f(i, j)) = 0 \quad (3.6)$$

et :

$$\frac{\partial \varepsilon}{\partial \alpha} = 2 \sum_{i=1}^p \sum_{j=1}^L i \cdot h(j) \cdot (h(j)(1 + \alpha \cdot i) - f(i, j)) = 0 \quad (3.7)$$

soit :

$$\sum_{j=1}^L \left(h(j) \sum_{i=1}^p (1 + \alpha \cdot i)^2 \right) = \sum_{j=1}^L \left(\sum_{i=1}^p (1 + \alpha \cdot i) \cdot f(i, j) \right) \quad (3.8)$$

et :

$$\sum_{j=1}^L \left(h(j)^2 \sum_{i=1}^p i \cdot (1 + \alpha \cdot i) \right) = \sum_{j=1}^L \left(h(j) \sum_{i=1}^p i \cdot f(i, j) \right) \quad (3.9)$$

La relation (3.8) nous donne :

$$h(j) = \frac{\sum_{i=1}^p f(i, j) + \alpha \sum_{i=1}^p i \cdot f(i, j)}{p + \alpha \cdot p \cdot (p + 1) + \alpha^2 \frac{p \cdot (p + 1) \cdot (2p + 1)}{6}} \quad (3.10)$$

La relation (3.9) nous donne :

$$\alpha = \frac{\sum_{j=1}^L \sum_{i=1}^p h(j) \cdot i \cdot f(i, j) - \frac{p \cdot (p + 1)}{2} \sum_{j=1}^L h(j)^2}{\frac{p \cdot (p + 1) \cdot (2p + 1)}{6} \sum_{j=1}^L h(j)^2} \quad (3.11)$$

En remplaçant l'expression de $h(j)$ dans (3.11), nous obtenons :

$$\alpha = \frac{(6 + 6 \cdot \alpha(p + 1) + \alpha^2(p + 1) \cdot (2p + 1)) \left(\sum_{j=1}^L \left(\sum_{i=1}^p f(i, j) \cdot \sum_{i=1}^p i \cdot f(i, j) \right) + \alpha \sum_{j=1}^L \left(\sum_{i=1}^p i \cdot f(i, j) \right)^2 \right)}{(p + 1) \cdot (2p + 1) \cdot \left(\sum_{j=1}^L \left(\sum_{i=1}^p f(i, j) \right)^2 + \alpha^2 \sum_{j=1}^L \left(\sum_{i=1}^p i \cdot f(i, j) \right)^2 + 2\alpha \sum_{j=1}^L \left(\sum_{i=1}^p f(i, j) \cdot \sum_{i=1}^p i \cdot f(i, j) \right) \right)} - \frac{3}{2p + 1}$$

Enfin, en posant :

$$\begin{cases} K_1 = \sum_{j=1}^L \left(\sum_{i=1}^p f(i, j) \cdot \sum_{i=1}^p i \cdot f(i, j) \right) \\ K_2 = \sum_{j=1}^L \left(\sum_{i=1}^p f(i, j) \right)^2 \\ K_3 = \sum_{j=1}^L \left(\sum_{i=1}^p i \cdot f(i, j) \right)^2 \end{cases}$$

Il vient :

$$\left(\left(\alpha + \frac{3}{2p+1} \right) (p+1)(2p+1) \right) (\alpha^2 \cdot K_3 + 2\alpha \cdot K_1 + K_2) - (K_1 + \alpha \cdot K_3) (6 + 6\alpha(p+1) + \alpha^2 (p+1)(2p+1)) = 0$$

soit :

$$\begin{aligned} & \alpha^2 (K_1 (p+1)(2p+1) - 3K_3 (p+1)) \\ & + \alpha (K_2 (p+1)(2p+1) - 6K_3) \\ & + 3K_2 (p+1) - 6K_1 = 0 \end{aligned} \quad (3.12)$$

La valeur de α est donc solution de cette équation du second degré. Nous déterminons ainsi la fonction de profil h et la fonction de modulation d'amplitude g affine sur le réseau pour chacune des orientations testées.

Nous obtenons par conséquent la réponse $\varepsilon(\theta)$ en chaque point de l'image. Les directions recherchées correspondent aux minima de cette réponse, pour lesquels le voisinage étudié correspond le mieux au modèle utilisé.

3.3.4 Résultats

3.3.4.1 Modulation d'amplitude affine

La validité de ce nouvel attribut, fondé sur un modèle affine, est vérifiée sur une texture de profil sinusoïdal de période $T = 10$ pixels, modulée par une fonction $g(i) = 1 + \alpha \cdot i$ de pente $\alpha = 0.5$ (Fig. 3.7).



Fig. 3.7 Modulation affine, orientation théorique et palette d'orientation

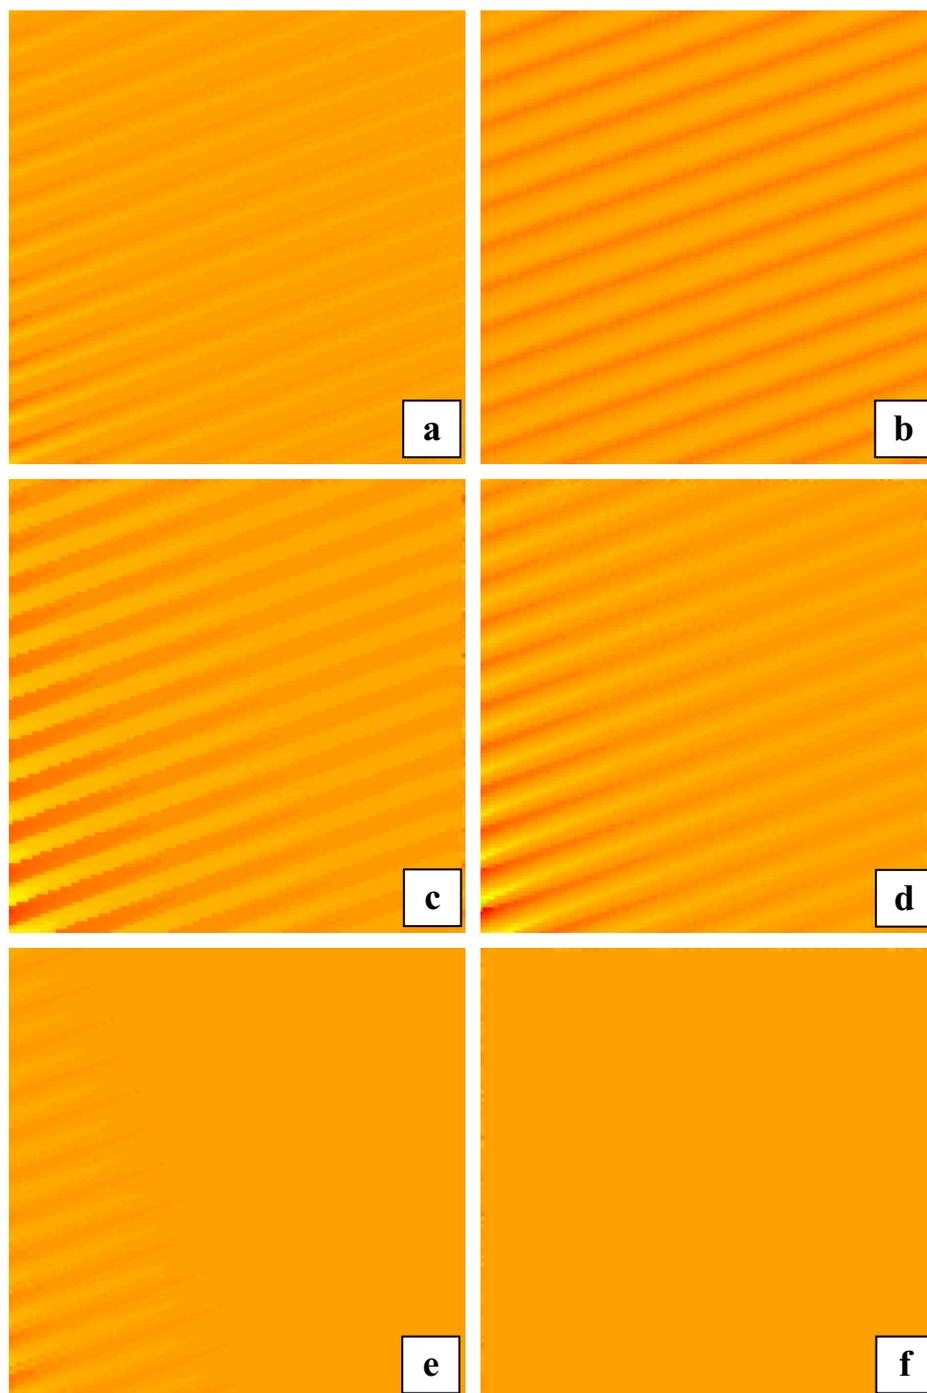


Fig. 3.8 Orientation estimée par les filtres steerable E2 (a), les filtres steerable E4 (b), l'opérateur IRON variationnelle (c) et IRON variance (d), les filtres de Gabor (e) et notre opérateur à modèle affine (f)

Les cartes d'orientations présentées (Fig. 3.8) sont obtenues à l'aide d'opérateurs ayant un pas d'échantillonnage des orientations $T_\theta = 1^\circ$, un facteur de forme $F = 1$ et une échelle d'analyse $E = 5$.

Pour la plupart des méthodes classiques d'estimation de l'orientation étudiées, l'erreur d'estimation est plus importante lorsque l'amplitude du profil est faible devant la modulation. Seul les filtres steerable E4 donnent une erreur constante quelle que soit l'amplitude du profil.

Notre opérateur fondé sur un modèle de profil modulé en amplitude ne présente pas d'autre erreur d'estimation que l'erreur due à l'échantillonnage de la réponse angulaire et fournit donc une réponse non biaisée.

En répétant l'estimation des orientations sur une telle image pour un grand nombre d'orientations, nous obtenons les valeurs d'Ecart Angulaire Moyen reportées dans le tableau suivant :

Opérateur	Steerable E2	Steerable E4	Variationnelle	Variance	Gabor	Modèle affine
EAM	1.16	1.28	2.77	1.93	0.53	0.25

Tab. 3.4 EAM obtenu avec différentes méthodes d'estimation

Dans le cas d'une image présentant des variations d'éclairage dans la direction de l'orientation, nous avons donc confirmé l'avantage de notre méthode sur les méthodes classiques d'estimation des orientations.

3.3.4.2 Modulation d'amplitude affine dans une direction quelconque

Notre analyse est fondée sur l'hypothèse que la modulation d'orientation apparaît dans la même direction que celle de la texture présente dans l'image étudiée.

Afin de vérifier l'importance de cette hypothèse, nous calculons, avec les mêmes paramètres que précédemment, les cartes d'orientations sur une image constituée d'un profil orienté à 20° modulé par un éclairage dans la direction 70° (Fig. 3.9 et Fig. 3.10).



Fig. 3.9 Modulation linéaire (orientation quelconque), orientation théorique et palette d'orientation

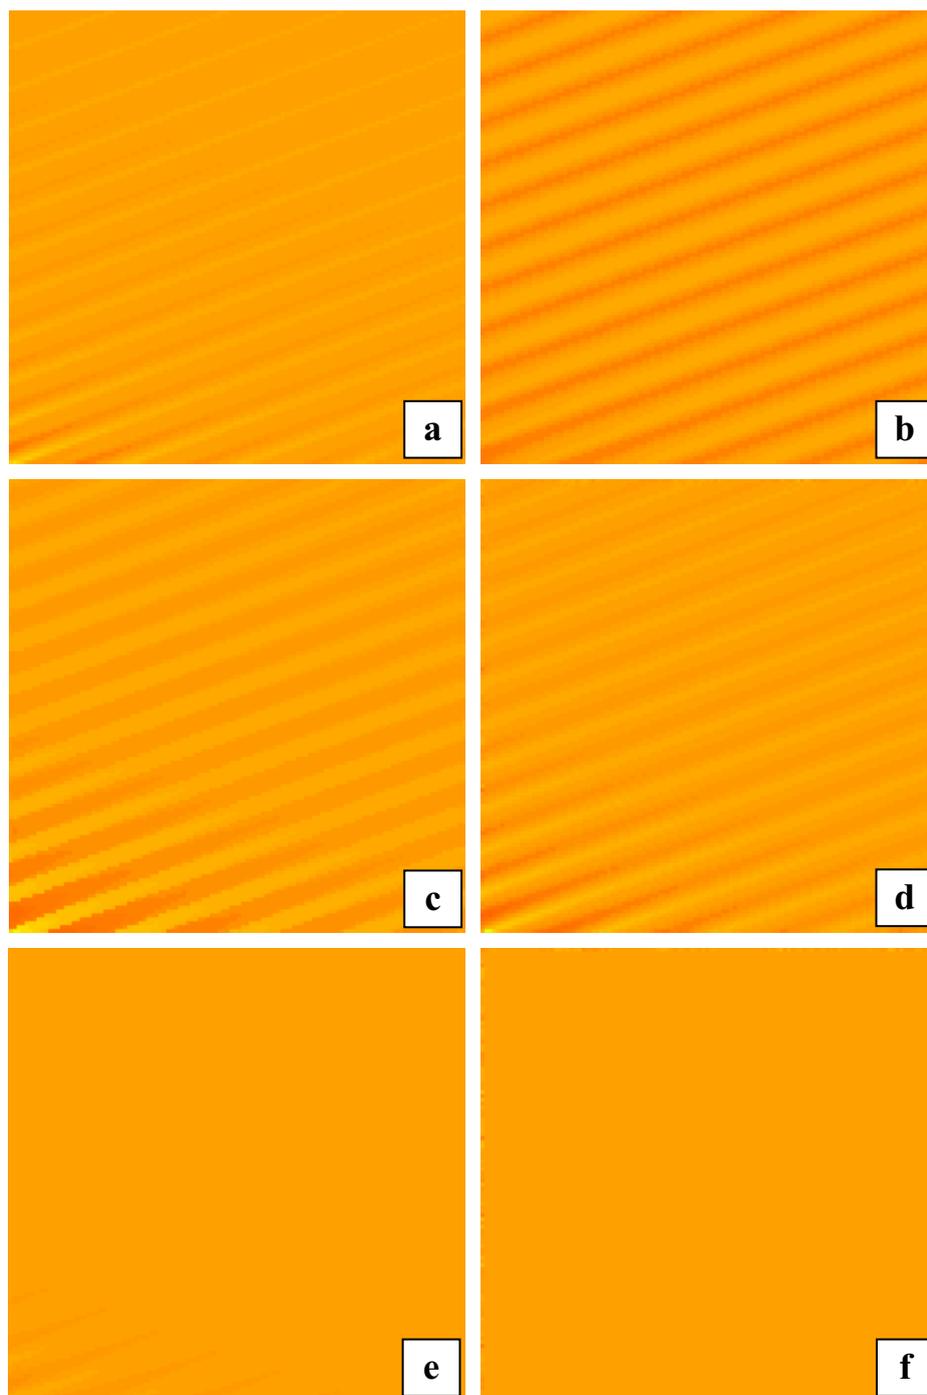


Fig. 3.10 Orientation estimée par les filtres steerable E2 (a), les filtres steerable E4 (b), l'opérateur IRON variationnelle (c) et IRON variance (d), les filtres de Gabor (e) et notre opérateur à modèle affine (f)

Dans une telle situation, l'allure générale des cartes d'orientation change peu par rapport à l'expérimentation précédente. Nous constatons que l'estimation obtenue par notre opérateur fondé sur le modèle de profil modulé en amplitude ne présente pas d'erreur d'estimation.

De plus, par rapport au test précédent, l'erreur d'estimation semble plus faible quelle que soit la méthode employée.

Ce phénomène s'explique en considérant le fait qu'une modulation d'amplitude affine dans une direction donnée correspond à la somme d'une modulation affine dans la direction de l'image et d'une autre modulation dans une direction perpendiculaire.

Or, les méthodes d'estimation de l'orientation ne sont pas sensibles à une modulation d'amplitude dans la direction orthogonale à l'orientation de la texture de l'image. En effet une telle modulation correspond uniquement à une modification de la fonction profil de l'image.

Lorsque nous faisons varier l'orientation de la modulation d'amplitude par rapport à l'orientation de l'image de 0° à 90° , nous obtenons les valeurs d'EAM présentées dans le tableau suivant :

Opérateur	Steerable E2	Steerable E4	Variationnelle	Variance	Gabor	Modèle affine
EAM	0.91	1.26	1.96	1.27	0.47	0.25

Tab. 3.5 EAM obtenu avec différentes méthodes d'estimation

Lors de la simulation, nous notons que pour la plupart des méthodes, l'EAM diminue lorsque la différence entre l'orientation de l'image et l'orientation de la modulation augmente : la modulation d'amplitude devient de plus en plus perpendiculaire à l'orientation de l'image et par conséquent perturbe de moins en moins l'estimation de l'orientation.

Pour la méthode fondée sur un modèle de profil modulé, l'erreur obtenue correspond uniquement à l'incertitude induite par la quantification des orientations.

Nous pouvons donc estimer les orientations d'une image modulée linéairement en amplitude dans une direction quelconque sans être perturbés par cette modulation.

3.3.4.3 Modulation d'amplitude non affine

Nous vérifions également la validité de l'hypothèse assimilant localement une modulation lente à une variation linéaire. L'image de la figure 3.11 présente une modulation d'amplitude sinusoïdale de fonction $g(i) = 1 + A_{\text{mod}} \cdot \sin(2\pi i / T_{\text{mod}})$, de période $T_{\text{mod}} = 50$ pixels et d'amplitude $A_{\text{mod}} = 0.5$.

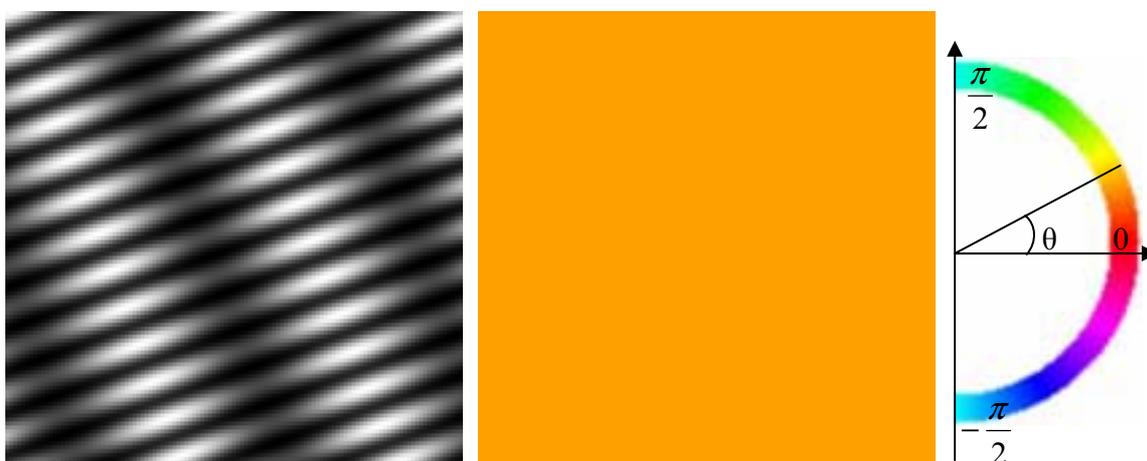


Fig. 3.11 Modulation sinusoïdale, orientation théorique et palette d'orientation

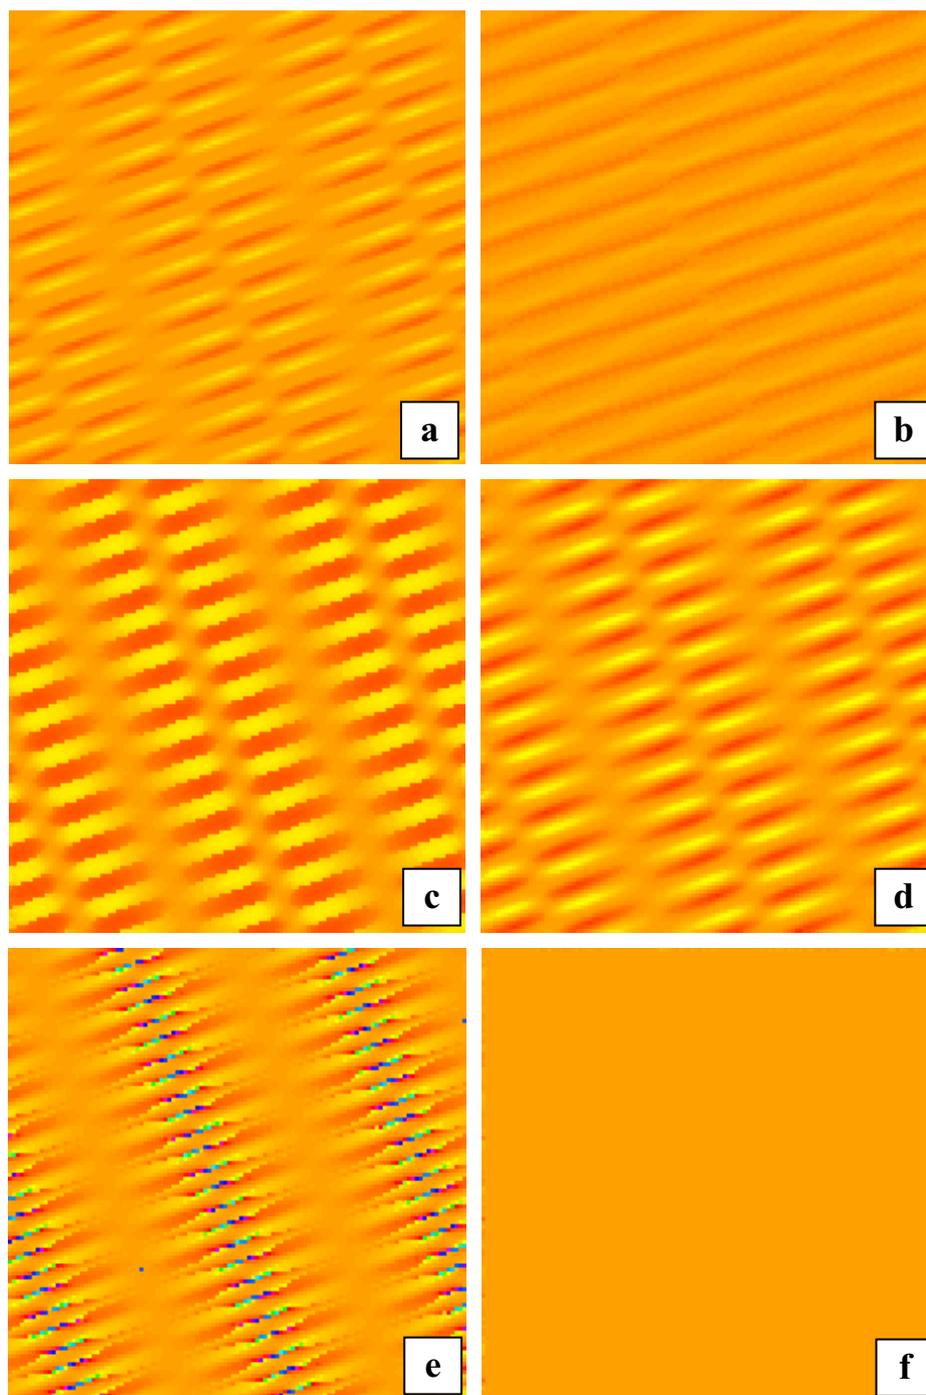


Fig. 3.12 Orientation estimée par les filtres steerable E2 (a), les filtres steerable E4 (b), l'opérateur IRON variationnelle (c) et IRON variance (d), les filtres de Gabor (e) et notre opérateur à modèle affine (f)

Nous obtenons les cartes d'orientations présentées (Fig. 3.12) à l'aide d'opérateurs ayant un pas d'échantillonnage des orientations $T_\theta = 1^\circ$, un facteur de forme $F = 1$ et une échelle d'analyse $E = 5$.

Au vu de ces cartes d'orientation, nous remarquons que la plupart des opérateurs ont un comportement comparable au cas linéaire, à l'exception des filtres de Gabor, qui semblent davantage sensibles à cette modulation périodique dans la direction orthogonale à l'image.

Nous observons également que l'opérateur fondé sur un modèle d'image modulée linéairement estime correctement les orientations dans cette situation.

De nouveau, nous évaluons les valeurs d'EAM pour plusieurs orientations d'image. Ces valeurs sont reportées dans le tableau suivant :

Opérateur	Steerable E2	Steerable E4	Variationnelle	Variance	Gabor	Pente
EAM	1.77	1.33	4.78	3.34	7.48	0.25

Tab. 3.6 EAM obtenu avec différentes méthodes d'estimation

En comparaison de l'estimation réalisée sur une image modulée linéairement, les filtres steerable E4 sont les moins affectés par cette modulation sinusoïdale de l'amplitude. A l'opposé, les filtres de Gabor y sont beaucoup plus sensibles.

Enfin, nous vérifions que l'opérateur fondé sur un modèle affine n'est pas sensible à une telle modulation : la seule erreur d'estimation résulte de la quantification angulaire.

3.3.4.4 Coût calculatoire

Tout comme l'attribut robuste, cette estimation de l'orientation par estimation de la pente locale n'est pas calculable récursivement. De plus, tous les pixels du réseau sont à chaque fois utilisés : nous ne pouvons pas effectuer de calcul séparable en x-y.

Pour une image 128×128 et pour une échelle d'analyse $E = 5$, le temps de calcul est de 330s alors qu'il est de 4.4s pour la variance.

3.4 Adaptation de l'échelle d'analyse

3.4.1 Problématique

L'orientation estimée sur une image peut dépendre fortement de l'échelle d'analyse retenue.

Notre objectif étant l'analyse des orientations locales, le choix d'une petite échelle est en général préférable. C'est en particulier le cas sur une image de profil sinusoïdal modulée en orientation : nous avons vu au chapitre 2.5.1.4 que plus l'échelle d'analyse est petite, plus l'erreur d'estimation de l'orientation locale est faible.

A l'inverse, sur une image bruitée d'orientation stationnaire (pour laquelle l'orientation locale correspond à l'orientation globale), plus l'échelle d'analyse est grande, moins l'estimation est sensible au bruit.

Plaçons nous maintenant dans le cas d'une image bruitée pour laquelle l'orientation locale ne correspond pas à l'orientation globale. Afin d'obtenir l'estimation de l'orientation la moins

erronée possible, nous devons donc, en ce qui concerne l'échelle E de l'opérateur IRON, faire un compromis entre la robustesse au bruit et le biais de l'estimation locale de l'orientation.

3.4.2 Etude de la réponse angulaire

Pour une image donnée, nous définissons l'échelle d'analyse optimale E_{opt} comme l'échelle minimisant l'erreur d'estimation de l'orientation.

Lors de l'analyse d'une image issue d'une scène réelle, nous ne disposons pas de l'orientation théorique recherchée : nous ne pouvons donc pas déterminer l'EAM en fonction de l'échelle. Pour estimer E_{opt} , nous devons donc définir un critère en nous fondant uniquement sur la réponse de l'opérateur utilisé.

La figure 3.13 présente une image bruitée (RSB=5dB) modulée en orientation. La figure 3.14 représente, pour différentes échelles d'analyse, les réponses angulaires obtenues au point A de cette image avec l'opérateur IRON fondé sur la variance des niveaux de gris.

Les échelles utilisées sont (de gauche à droite) $E=5$, $E=10$, $E=20$ et $E=30$ pixels, avec un facteur de forme unitaire.

Nous observons deux phénomènes sur ces réponses angulaires :

- la largeur du pic correspondant à l'orientation détectée est de plus en plus faible lorsque l'échelle E augmente ;
- le rapport entre la hauteur du pic et la valeur minimale de la courbe diminue lorsque l'échelle augmente. Nous avons vu au chapitre 2.3.2.3 que cette valeur minimale ne dépend pas de l'échelle mais uniquement de l'image étudiée.

C'est donc la hauteur du pic qui diminue quand l'échelle augmente, même si la mise à l'échelle automatique du tracé nous donne l'impression que c'est la valeur minimale qui augmente.

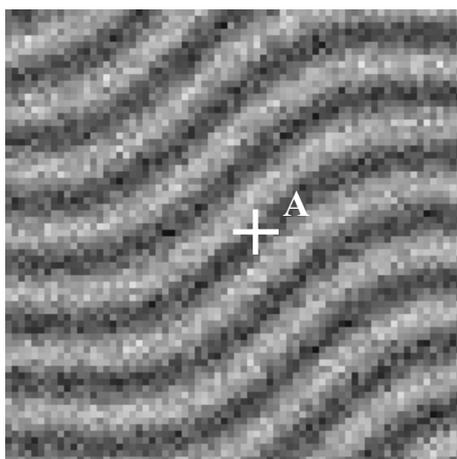


Fig. 3.13 Image bruitée modulée en orientation

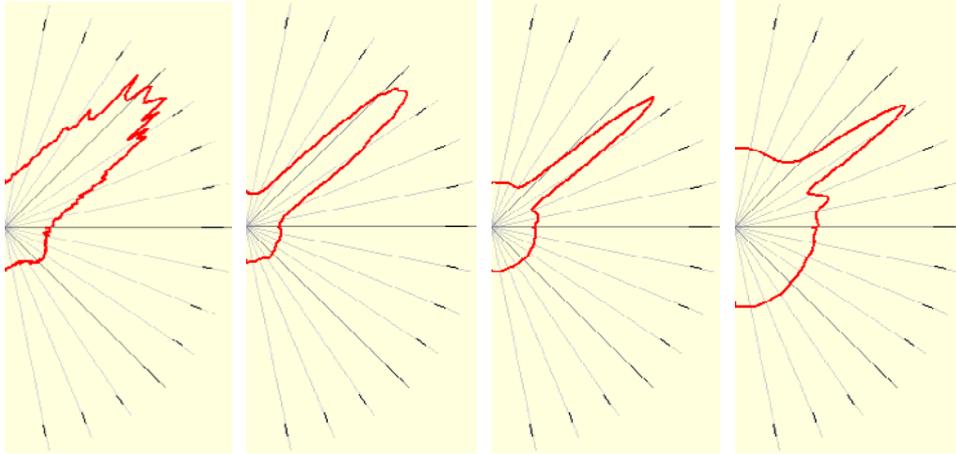


Fig. 3.14 Réponses angulaires au point A pour différentes échelles E

Le premier phénomène est lié à la robustesse au bruit de l'opérateur IRON : plus l'échelle augmente, moins l'opérateur est perturbé par le bruit.

Le deuxième phénomène est lié à la modulation d'orientation : plus l'échelle E augmente, moins nous pouvons assimiler les lignes de niveau à des segments de droite.

Par conséquent nous pouvons considérer que l'échelle d'analyse E est appropriée à l'estimation des orientations quand nous avons à la fois une bonne robustesse au bruit et une bonne correspondance entre notre modèle d'image orientée et le voisinage étudié.

L'objectif recherché se traduit donc par la présence simultanée d'un pic étroit et d'un rapport maximum/minimum élevé.

3.4.3 Solution envisagée

En se basant uniquement sur l'allure de la réponse angulaire de l'opérateur IRON fondé sur l'estimation de la variance, nous définissons un critère permettant d'approcher l'échelle d'analyse optimale E_{opt} .

Nous définissons R_S le rapport entre d'une part l'intégrale, sur l'ensemble des angles étudiés, de la différence entre la réponse angulaire et le minimum de cette réponse, et d'autre part l'intégrale de la différence entre le maximum de la courbe et la réponse angulaire.

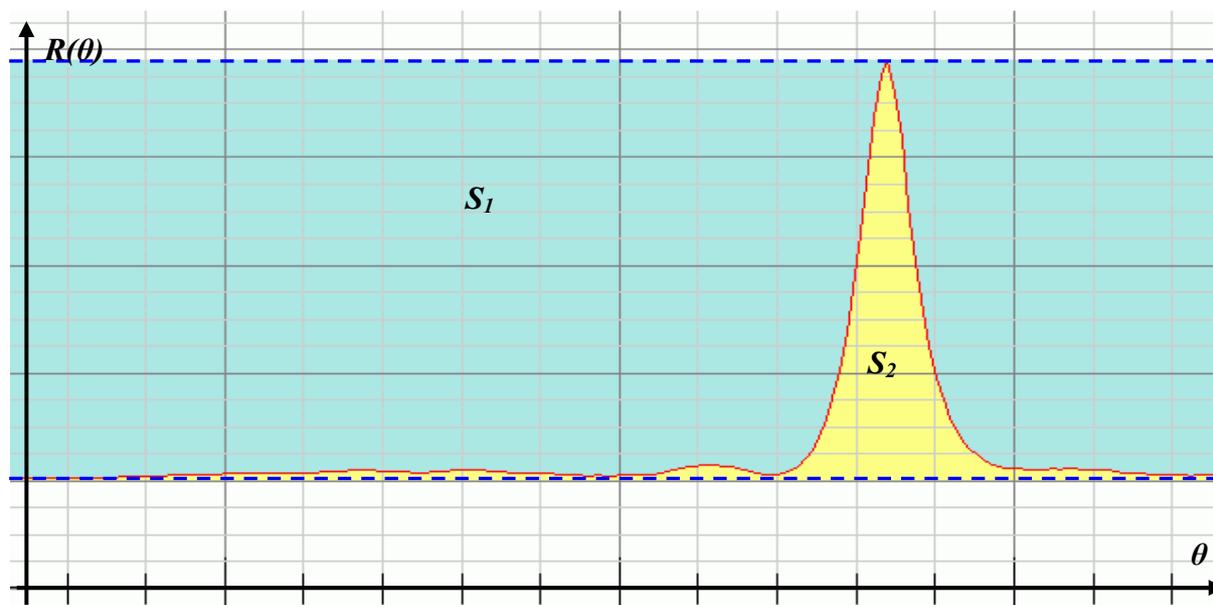
Sur la figure 3.15, le rapport R_S correspond au rapport entre la surface S_1 bleue (foncé) et la surface S_2 jaune (clair).

$$R_S = \frac{S_1}{S_2} \quad (3.13)$$

avec :

$$\begin{cases} S_1 = \int_{\Omega} (H_{MAX} - H(\theta)) d\theta \\ S_2 = \int_{\Omega} (H(\theta) - H_{MIN}) d\theta \end{cases}, \Omega = [0, \pi] \text{ ou } [0, 2\pi] \quad (3.14)$$

Nous supposons que lorsque ce rapport est maximal, l'échelle d'analyse E est proche de l'échelle optimale E_{opt} .

Fig. 3.15 Critère surfacique R_S

3.4.4 Résultats

3.4.4.1 Estimation globale de l'échelle optimale

Nous illustrons la démarche proposée par des images constituées d'un profil sinusoïdal de période $T = 10$ pixels, modulé en orientation par une fonction périodique de période $T_{\text{mod}} = 50$ puis $T_{\text{mod}} = 75$ pixels. Les deux images sont bruitées par un bruit blanc gaussien additif (RSB = 0dB)(Fig. 3.16).

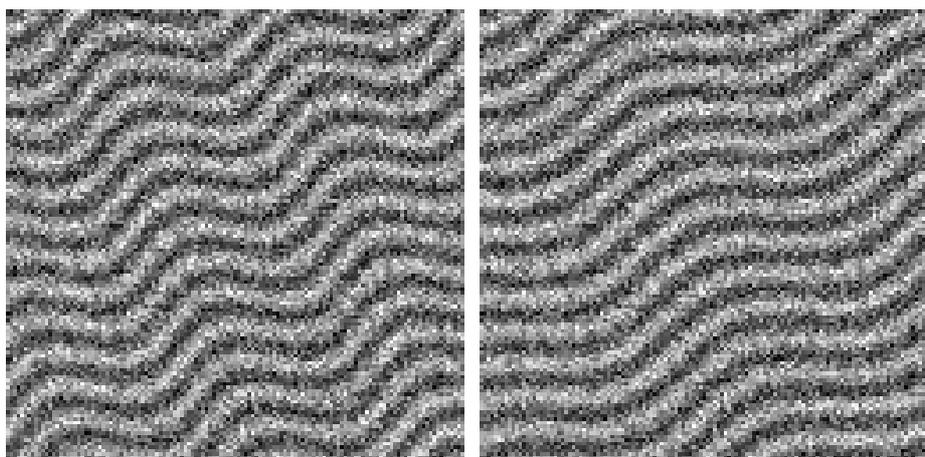


Fig. 3.16 Modulation d'orientation et bruit blanc

Respectivement pour chacune de ces images, la figure 3.17 et la figure 3.18 font apparaître, en fonction de l'échelle d'analyse E , l'évolution de l'EAM et de notre critère R_S moyenné sur l'image.

Le réseau utilisé est un réseau symétrique de facteur de forme $F = 1$.

Pour une plus grande lisibilité, nous traçons la courbe $-R_s$, dont nous déterminons le maximum en valeur absolue.

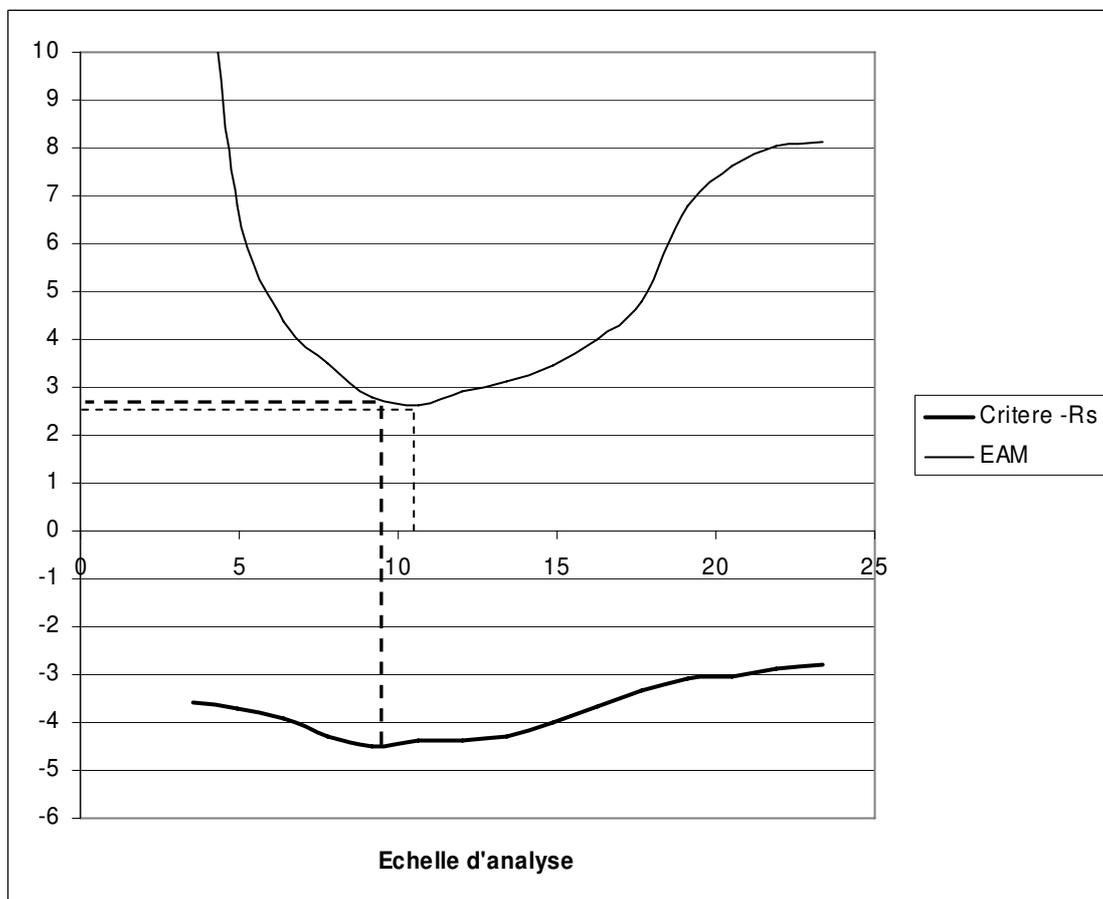


Fig. 3.17 EAM et critère surfacique R_s en fonction de l'échelle E ($T_{\text{mod}} = 50$)

Dans le premier cas, l'échelle d'analyse qui maximise le critère R_s est $E = 9.2$ (soit un réseau de 13 lignes et 13 points par ligne), alors que l'échelle optimale vis-à-vis de l'EAM est $E_{\text{opt}} = 10.6$ (soit un réseau de 15 lignes et 15 points par ligne).

La différence constatée entre l'estimation de l'échelle optimale et sa valeur réelle est faible. En effet les réseaux utilisés ont des dimensions impaires, et par conséquent le réseau de taille 15×15 est directement consécutif à celui de dimensions 13×13 .

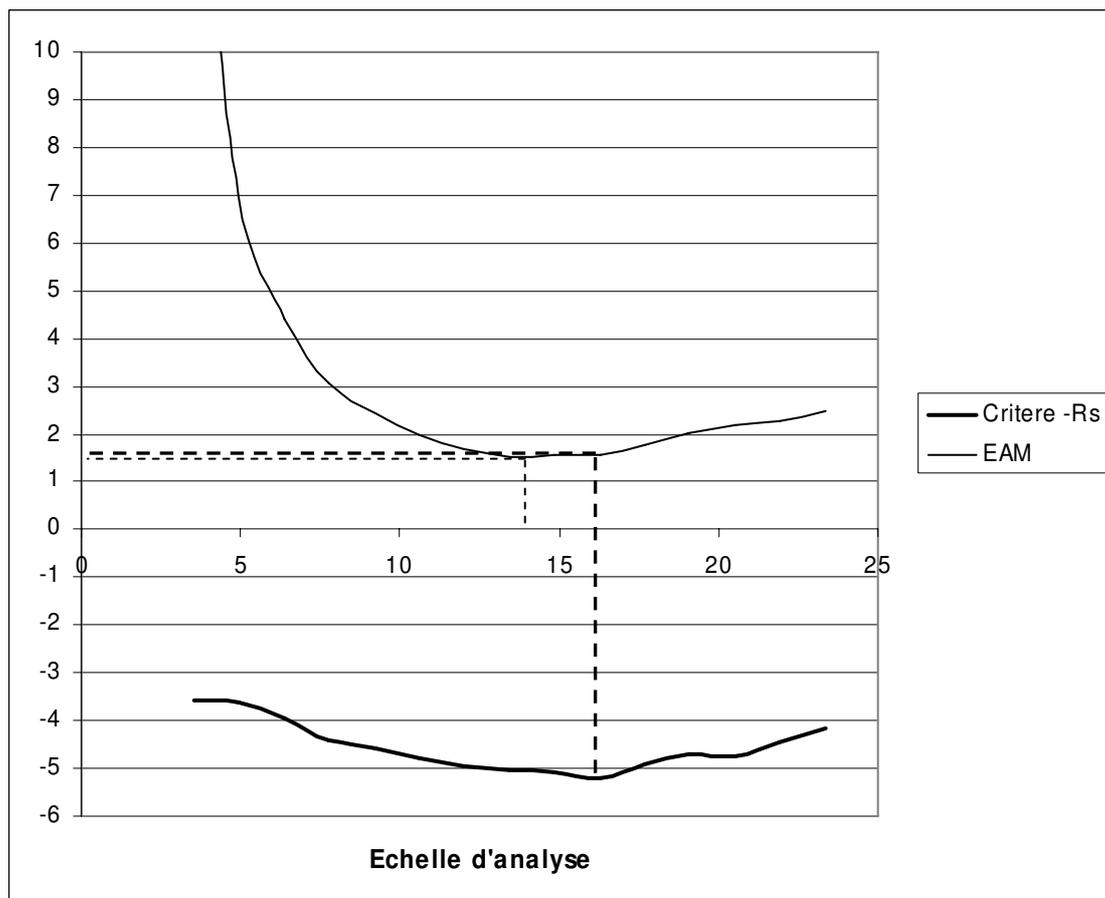


Fig. 3.18 EAM et critère surfacique R_s en fonction de l'échelle E ($T_{\text{mod}} = 75$)

Dans le deuxième cas l'échelle d'analyse maximisant le critère R_s est $E = 16.3$ (réseau de 23 lignes et 23 points par ligne), alors que l'échelle minimisant l'EAM est $E_{\text{opt}} = 13.4$ (réseau de 19 lignes et 19 points par ligne).

Dans ce cas de figure, l'erreur commise sur l'échelle optimale est plus importante. Nous notons cependant que la variation d'erreur d'estimation des orientations qui en découle est très faible (0.026°). En effet dans cette plage de valeurs d'échelle, la précision de l'estimation varie peu.

En multipliant les tests, nous remarquons que l'estimation de l'échelle optimale a plus souvent tendance à surestimer la valeur recherchée qu'à la sous-estimer.

3.4.4.2 Construction d'un estimateur adaptatif

En fonction de la courbure locale, l'échelle d'analyse optimale peut varier sur l'image. Nous pouvons facilement concevoir que cette échelle est plus grande dans les zones de l'image présentant une faible courbure locale, alors qu'elle est plus petite dans les zones présentant une forte courbure.

Nous souhaitons donc pouvoir déterminer l'échelle d'analyse la plus adaptée en chaque point de l'image, et non plus pour l'ensemble de l'image.

Ceci s'effectue directement en choisissant en chaque point de l'image l'échelle E qui maximise localement notre critère R_S . Nous espérons ainsi améliorer la qualité de notre estimation de l'orientation.

Nous étudions ici une image de profil sinusoïdal (période $T = 10$ pixels) modulé en orientation par une fonction périodique de période $T_{\text{mod}} = 75$ pixels (Fig. 3.19). Cette image est bruitée par un bruit blanc gaussien à un RSB de 5dB.

Sur cette image, l'erreur minimale d'estimation $EAM = 1.09^\circ$ est obtenue pour une échelle globale $E_{\text{opt}} = 12$ (réseau 17×17). Notre estimation de l'échelle optimale est $\hat{E}_{\text{opt}} = 16.3$ (réseau 23×23) et conduit à une erreur d'estimation moyenne $EAM = 1.36^\circ$.

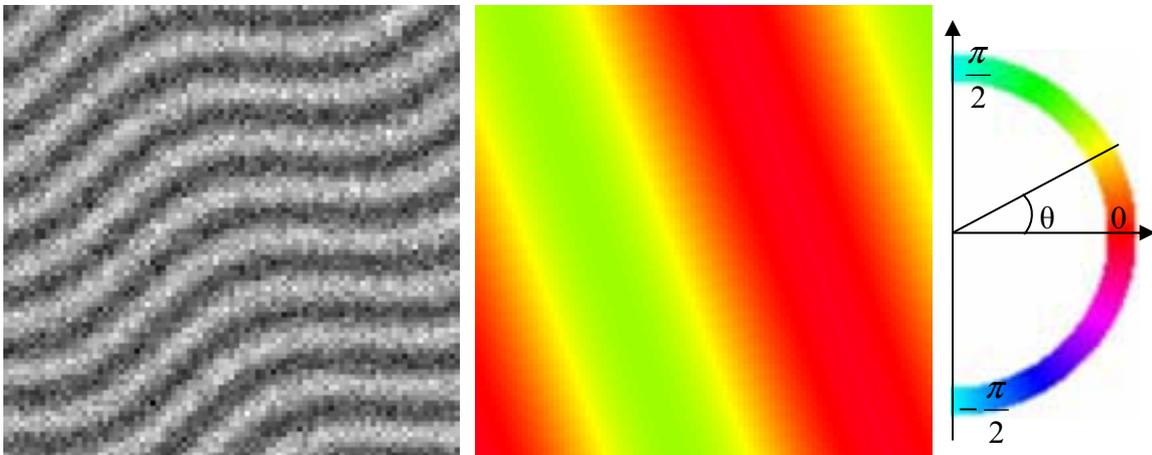


Fig. 3.19 Modulation d'orientation bruitée (5dB), orientation théorique et palette d'orientation

Nous avons jusque là estimé l'échelle optimale de manière globale sur toute l'image. La courbure locale n'étant pas identique sur toute l'image, nous pouvons améliorer notre estimation de l'orientation en estimant localement l'échelle optimale.

La carte des échelles E qui maximisent localement le critère R_S est présentée en figure 3.20.

A cause de la forte influence du bruit, cette carte d'échelle est elle aussi bruitée. Par conséquent, la carte d'orientation associée à cette carte d'échelle (Fig. 3.21) présente elle aussi des fluctuations rapides.

Ce désordre supplémentaire de la carte d'orientation dégrade la qualité de l'estimation : l'erreur angulaire moyenne d'estimation vaut $EAM = 1.59^\circ$.

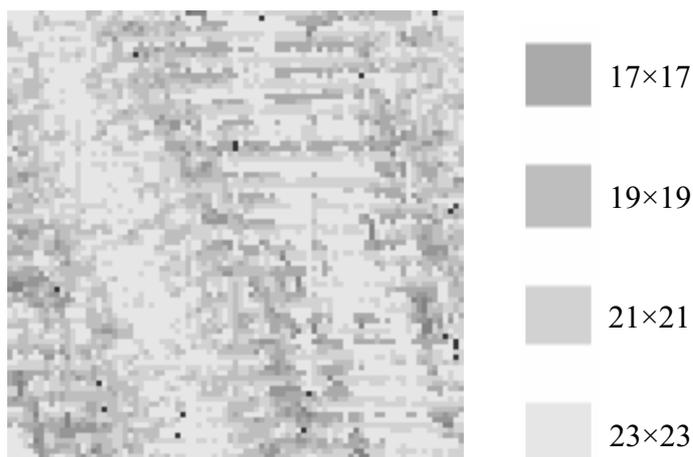


Fig. 3.20 Carte d'échelle maximisant R_s et tailles de réseau correspondantes

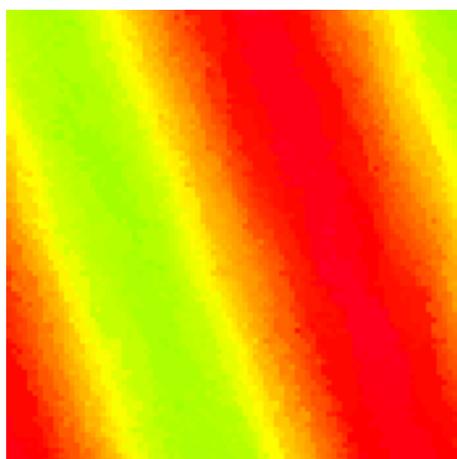


Fig. 3.21 Carte d'orientation obtenue

Les variations de l'échelle d'analyse optimale sont supposées lentes et il est par conséquent possible de régulariser la carte d'échelle précédente en utilisant un filtre médian de taille appropriée (nous utilisons ici un filtre médian 11×11).

La carte d'échelle ainsi obtenue (Fig. 3.22) fait néanmoins apparaître que l'échelle appropriée à l'étude de cette image est plus grande dans les zones de faible courbure que dans les zones de forte courbure de l'image.

La carte d'orientation obtenue est ainsi proche de la carte théorique. En utilisant le lissage de la carte d'échelle, l'erreur d'estimation moyenne vaut $EAM = 1.2^\circ$. Cette erreur, sans être inférieure à l'erreur obtenue en utilisant l'échelle optimale globale, est tout de même plus faible que l'erreur que nous obtenions en utilisant l'échelle globale estimée à l'aide du critère surfacique.



Fig. 3.22 Carte d'échelle régularisée et tailles de réseau correspondantes

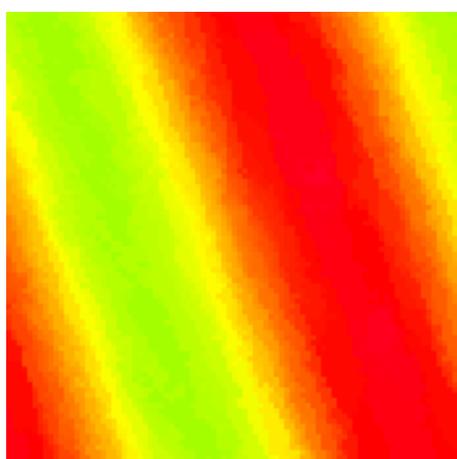


Fig. 3.23 Carte d'orientation obtenue

Dans l'exemple précédent, l'échelle optimale d'analyse varie peu. C'est pourquoi l'estimation effectuée à l'échelle optimale globale théorique E_{opt} est plus précise que l'estimation utilisant la carte de l'estimation de l'échelle optimale locale.

L'estimation adaptative présente un avantage significatif si l'image étudiée comporte d'importantes variations de courbure. C'est en particulier le cas sur l'image de la figure 3.24, représentant des cercles concentriques de profil sinusoïdal, modulés en orientation, et bruités par un bruit blanc gaussien additif à un RSB de 5dB.

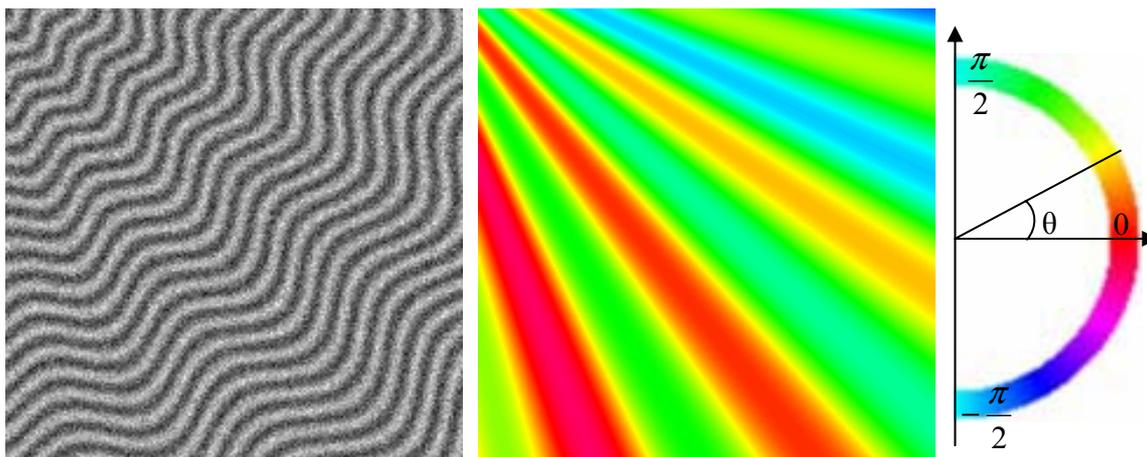


Fig. 3.24 Cercles concentriques modulés en orientation, orientation théorique et palette d'orientation

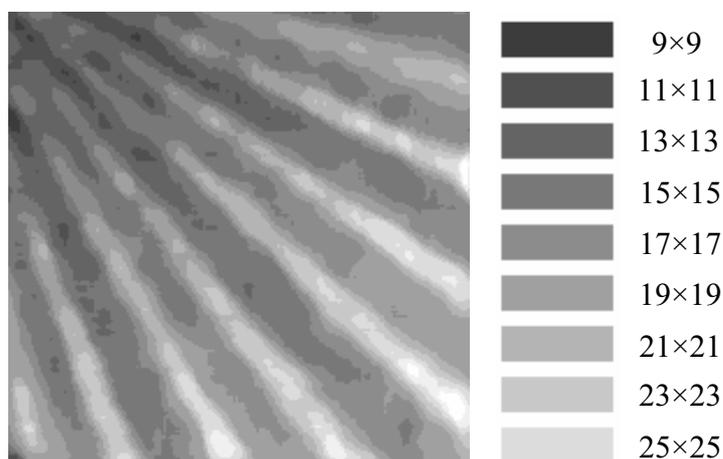


Fig. 3.25 Carte d'échelle régularisée et tailles de réseau correspondantes

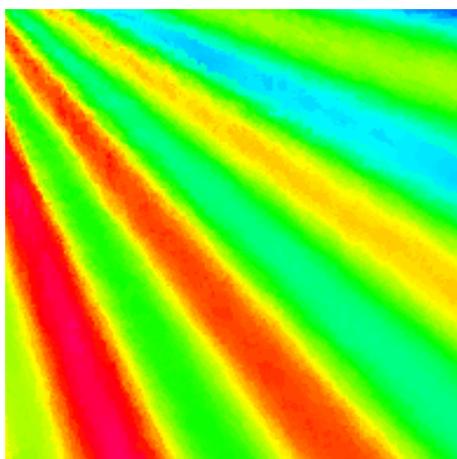


Fig. 3.26 Carte d'orientation obtenue

Pour cette image, la valeur de l'échelle optimale globale est $E_{opt} = 9.2$ (réseau 13×13). A cette échelle, l'erreur moyenne d'estimation de l'orientation locale vaut $EAM = 1.9^\circ$.

Grâce à l'attribut surfacique R_s , nous estimons cette échelle globale à $\hat{E}_{opt} = 12$ (réseau 17×17). L'erreur moyenne d'estimation vaut alors $EAM = 2.4^\circ$.

En effectuant une estimation adaptative de l'orientation fondée sur la carte lissée de l'estimation de l'échelle optimale (Fig. 3.25), nous obtenons une erreur moyenne $EAM = 1.7^\circ$. La carte des orientations correspondante apparaît en figure 3.26.

Par conséquent, sur cette image où les variations de l'échelle d'analyse optimale locale sont plus importantes, l'estimation adaptative de l'orientation se révèle plus précise que l'estimation utilisant l'échelle optimale globale théorique.

De plus, il convient de garder à l'esprit que l'échelle optimale globale théorique ne peut être connue que si l'on connaît la carte de l'orientation locale théorique.

Ainsi, la méthode proposée pour estimer l'échelle optimale d'estimation des orientations s'est montrée efficace. Nous pouvons estimer cette échelle globalement ou localement. Par rapport à une estimation globale, une estimation locale de l'échelle optimale améliore les résultats d'estimation de l'orientation.

Le coût calculatoire de cet opérateur adaptatif est directement proportionnel au nombre d'échelles testées. Dans le cas de notre étude nous avons testé 20 tailles de réseau, de 5×5 à 43×43 . Le temps de calcul était donc 20 fois celui correspondant à l'estimation de l'orientation sur une image par l'opérateur IRON variance.

3.5 Conclusion

A travers ce chapitre, nous avons vu qu'il est possible d'adapter l'opérateur IRON à l'image à traiter en fonction de la connaissance a priori dont nous disposons sur cette image.

Cette adaptation porte sur les deux paramètres essentiels de l'opérateur IRON : l'attribut calculé et la géométrie du réseau.

Le choix de l'attribut calculé est déterminé par rapport à l'application envisagée :

- la variationnelle privilégie la sélectivité angulaire par rapport à la résistance au bruit
- la variance présente une bonne immunité au bruit blanc
- l'attribut robuste MAD est peu sensible aux bruits impulsionnels
- l'attribut estimant la pente locale permet de s'affranchir des éventuelles modulations d'amplitude

En fonction de la quantité d'information à traiter, le coût calculatoire de chaque attribut peut être pénalisant. Les deux premières méthodes sont bien moins coûteuses que les deux dernières.

En ce qui concerne la géométrie, l'échelle d'analyse E peut être choisie manuellement si l'utilisateur dispose d'une connaissance suffisante sur l'image à traiter.

L'échelle d'analyse appropriée peut également être estimée automatiquement pour toute l'image, ou localement si l'image présente de fortes variations de courbure.

Le facteur de forme F est quant à lui choisi en fonction de la sélectivité angulaire souhaitée par l'utilisateur.

Enfin la symétrie du réseau dépend du type de résultat attendu : un réseau symétrique conduira à une estimation de l'orientation *modulo* π alors qu'un réseau asymétrique conduira à une estimation *modulo* 2π .

Ainsi l'opérateur IRON peut opérer sur une grande variété d'images et l'utilisateur n'a que peu de réglages à effectuer pour parvenir à une estimation précise des orientations.

Chapitre 4

Applications

4.1 Introduction

Un certain nombre d'applications en traitement numérique des images requièrent une mesure précise de l'orientation. C'est ainsi que l'opérateur IRON se révèle d'un grand intérêt dans les problématiques suivantes :

- la caractérisation de matériaux,
- la segmentation en télédétection,
- l'analyse d'images sismiques,
- la caractérisation d'empreintes digitales, etc.

Dans ce chapitre, nous présenterons les deux premières applications : la caractérisation de matériaux et la segmentation d'images issues de la télédétection pour l'étude des domaines viticoles.

4.2 Caractérisation de matériaux composites carbonés

L'application du traitement numérique des images à la caractérisation de matériaux composites carbonés entre dans le cadre d'une collaboration industrielle avec la société Snecma Propulsion Solide (Groupe Safran).

L'analyse de certains matériaux stratifiés permet d'évaluer le processus de fabrication, afin de s'assurer de la fiabilité du produit final. Cette analyse demande une grande expertise. Il s'agit ici de remplacer un contrôle jusqu'ici effectué manuellement par un contrôle automatisé.

Pour la clarté de la discussion, les résultats de cette application numérique sont présentés ici sur des images de matériau volontairement réalisé avec de fortes ondulations.

4.2.1 Problématique

4.2.1.1 Contexte

Les matériaux étudiés sont des matériaux composites stratifiés, sur lesquels les empilements de strates présentent des déformations. Un exemple d'un tel matériau peut être observé en figure 4.1. Les images de matériau sont obtenues à l'aide d'un banc macrographique.

L'amplitude des déformations est en général importante à la surface de l'empilement, mais leur amplitude diminue en même temps que la distance à la surface augmente.

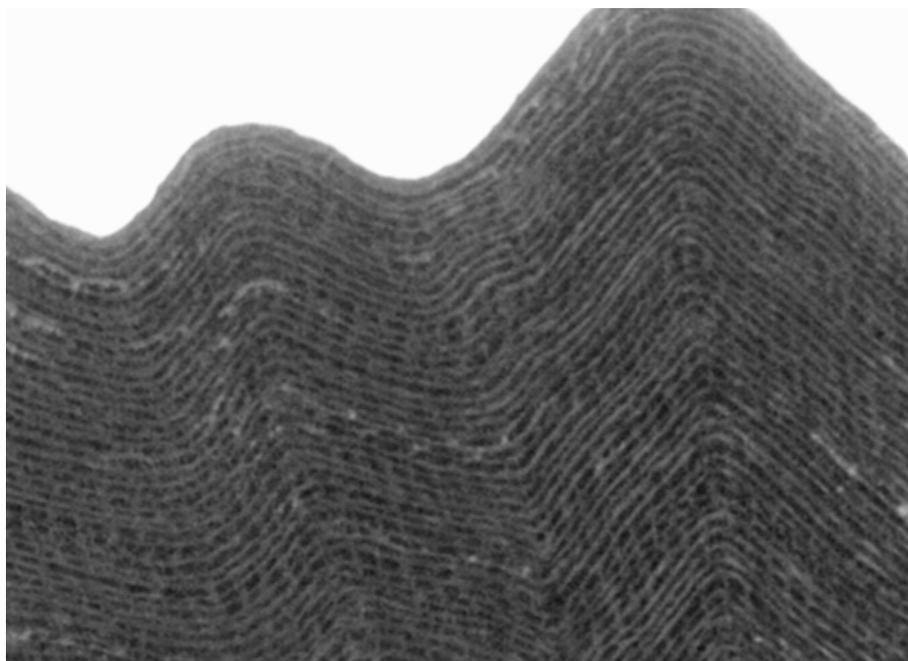


Fig. 4.1 Ondulations dans un matériau composite stratifié

4.2.1.2 Objectifs

Les déformations de l'empilement influent sur les caractéristiques mécaniques d'un tel matériau stratifié. Dans le cadre du contrôle de qualité, il est donc important de bien connaître les déformations présentes. Afin de répondre à cet objectif il convient de mesurer les ondulations dans le matériau. Comme ces ondulations ne sont pas identiques en tout point de l'empilement, on désire effectuer cette mesure individuellement pour chaque strate.

L'étape fondamentale conduisant à la mesure des déformations consiste donc à détecter les strates et à les suivre le long des déformations. Une fois les strates identifiées, il est possible de mesurer la largeur et l'amplitude des déformations mais aussi d'autres propriétés du matériau comme la distance inter strates.

4.2.2 Solution envisagée

4.2.2.1 Principe

Observées en coupe, les strates du matériau forment des motifs parallèles. L'orientation de ces motifs est un paramètre déterminant pour la caractérisation du matériau.

Notre méthode de détection des strates se structure en deux étapes :

- l'estimation de l'orientation locale des strates en chaque point de l'image.
- l'utilisation de cette carte d'orientation pour le suivi de chaque strate.

4.2.2.2 Cartes d'orientation

Nous utilisons l'opérateur IRON pour estimer en chaque point l'orientation des strates.

Dans les images que nous avons à traiter, les strates ne sont pas continues et il est possible d'observer localement deux orientations : l'orientation des strates et une orientation secondaire, généralement perpendiculaire aux strates, qui correspond aux discontinuités observables le long des strates. Cette deuxième orientation présente une cohérence plus faible que l'orientation des strates. Chercher l'orientation des strates revient donc à chercher l'orientation locale principale, celle présentant la plus grande confiance.

L'attribut choisi est la variationnelle, cet attribut étant moins sensible que la variance aux importantes variations de niveau de gris dues aux discontinuités des strates

Le facteur de forme est choisi à la valeur $F=1$, car nous nous intéressons uniquement à l'orientation principale de l'image en chaque point, sans contraintes sur la sélectivité angulaire.

L'échelle d'analyse vaut $E=29$, ce qui correspond à un réseau de dimensions 41×41 . Le choix de cette échelle d'analyse a été déterminé en rapport avec les images de la base de données : en fonction de la résolution des images, cette largeur de réseau de 41 pixels correspond à environ 3 ou 4 fois l'épaisseur d'une strate.

Nous calculons l'orientation d'une portion de l'image du matériau composite (Fig. 4.1). La carte d'orientation obtenue apparaît en figure 4.2.

L'estimation de l'orientation par l'opérateur IRON est très satisfaisante en comparaison des résultats obtenus par d'autres méthodes d'estimation. L'aspect visuel des cartes d'orientation (homogénéité des régions et régularité des contours) justifie ce jugement.

Le meilleur résultat obtenu avec d'autres méthodes est fourni par les filtres de Gabor (Annexe I).

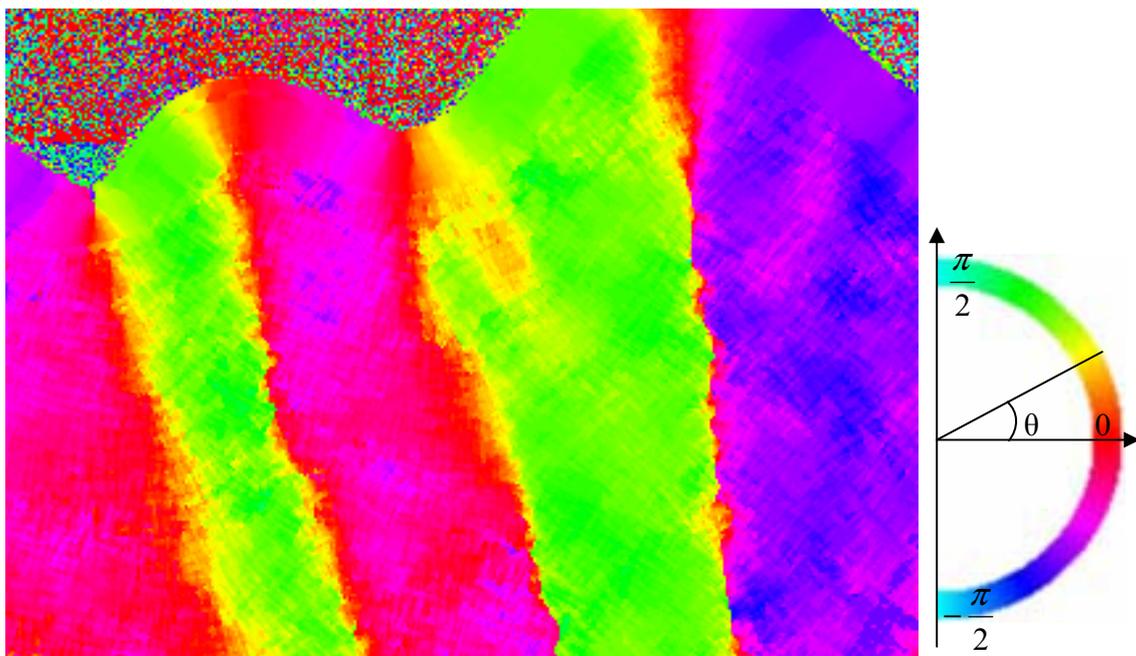


Fig. 4.2 Carte d'orientation estimée par l'attribut variationnelle (réseau symétrique 41×41)

4.2.2.3 Suivi des strates par intégration de la pente

Si nous connaissons avec précision l'orientation d'une strate et si nous connaissons les coordonnées d'un point appartenant à cette strate, il est en possible de reconstruire cette strate.

Soit $C = \{y = f_s(x)\}$ l'ensemble des points représentant la courbe C suivie par la strate S .

Etant donné les caractéristiques d'une strate, nous pouvons supposer que f_s est continue et dérivable. L'orientation locale $\theta_s(x_0)$ de la strate S au point d'abscisse x_0 peut donc être associée à la pente $\frac{\partial f_s}{\partial x}(x_0)$ de la courbe C décrite par la strate :

$$\frac{\partial f_s}{\partial x}(x_0) = \tan(\theta_s(x_0)) \quad (4.1)$$

La connaissance de l'orientation locale $\theta(x, y)$ de l'image ainsi que les coordonnées (x_s, y_s) d'un point appartenant à la strate S nous permettent donc de retrouver la position y_s' de la strate dans l'image pour n'importe quelle valeur d'abscisse x_s' :

$$y_s' = y_s + \int_{x=x_s}^{x_s'} \tan(\theta_s(x)) dx \quad (4.2)$$

La figure 4.3 illustre cette idée. Une succession de vecteurs, situés à des coordonnées non entières de l'image, reconstituent une estimation du tracé des strates sombres sur l'image.

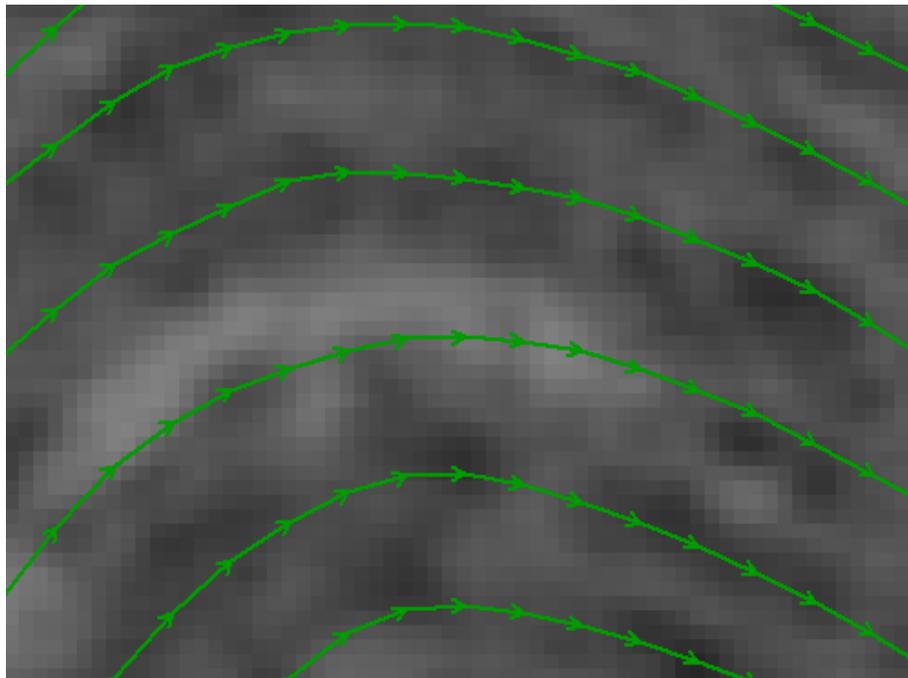


Fig. 4.3 Suivi des strates par intégration de leur pente

Deux phénomènes nous empêchent d'exploiter directement cette méthode.

- Tout d'abord, au vu des fortes perturbations présentes sur l'image, la carte d'orientation estimée ne correspond pas exactement à la pente de la courbe représentant la strate. L'intégration des erreurs d'estimation sur toute la largeur de l'image conduit à une dérive de la position estimée de la strate par rapport à sa position réelle.

- Le pas d'intégration utilisé pour approximer l'intégration n'est pas infiniment petit, et par conséquent cette approximation entraîne aussi une dérive du suivi des strates.

Il est donc nécessaire d'effectuer une correction sur le suivi des strates : la méthode que nous proposons pour le suivi des strates repose sur le principe d'intégration de la pente décrit précédemment en incluant une mise à jour et une correction de la position de la strate.

Le traitement de l'image par cette méthode s'effectue colonne par colonne.

Pour chaque pixel de la colonne, notre méthode utilise l'orientation locale pour effectuer une moyenne des niveaux de gris parallèlement aux strates.

Une strate apparaissant en sombre sur l'image, les positions des strates sur la colonne étudiée correspondent alors à des minima verticaux de la moyenne des niveaux de gris.

4.2.3 Résultats

Grâce à cette méthode, nous sommes capables de détecter les strates dans les images d'enroulements de fibres.

Une image des résultats obtenus par cette méthode est présentée en figure 4.4. Les positions des strates détectées y sont marquées en blanc.

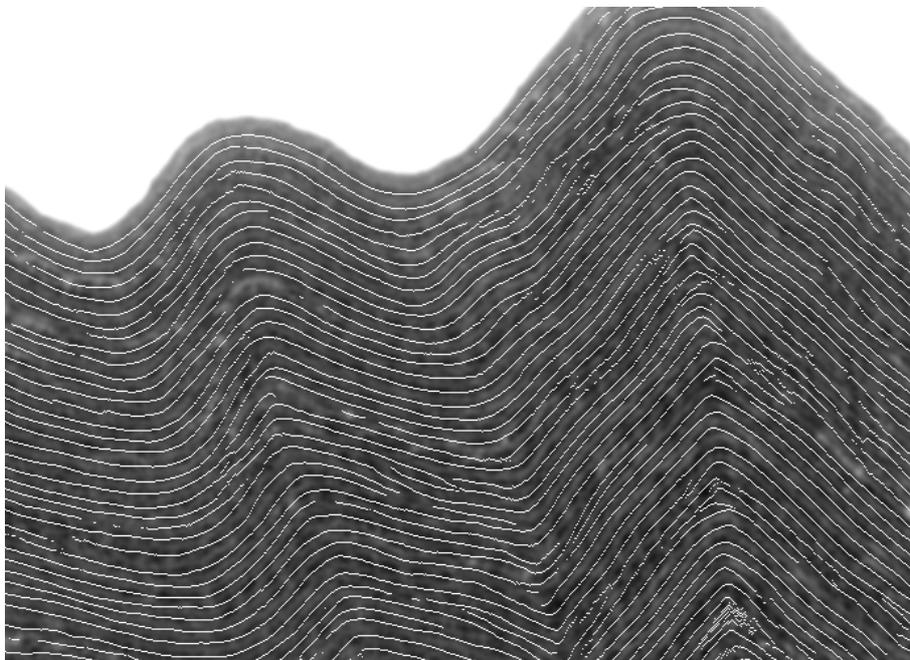


Fig. 4.4 Détection des strates par sommation des niveaux de gris le long des strates

Bien que satisfaisante, cette méthode est perfectible. Nous pouvons noter en particulier trois types d'erreurs dans cette image.

Le premier type d'erreur rencontré correspond à une variation brutale de la position détectée de la strate. Un tel phénomène est présenté en figure 4.5.

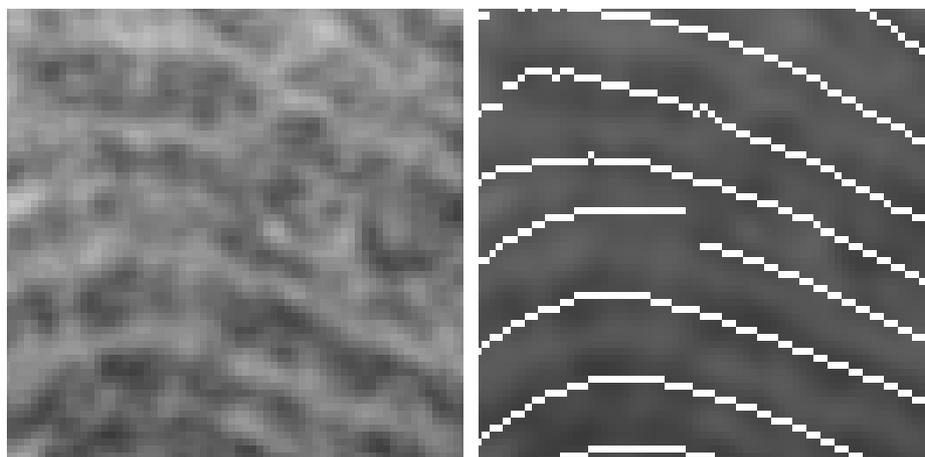


Fig. 4.5 Discontinuité de la strate

Une autre erreur qui se produit en certaines zones de l'image correspond à la non détection d'une strate, sur un intervalle plus ou moins long. La figure 4.6 illustre une telle non détection.

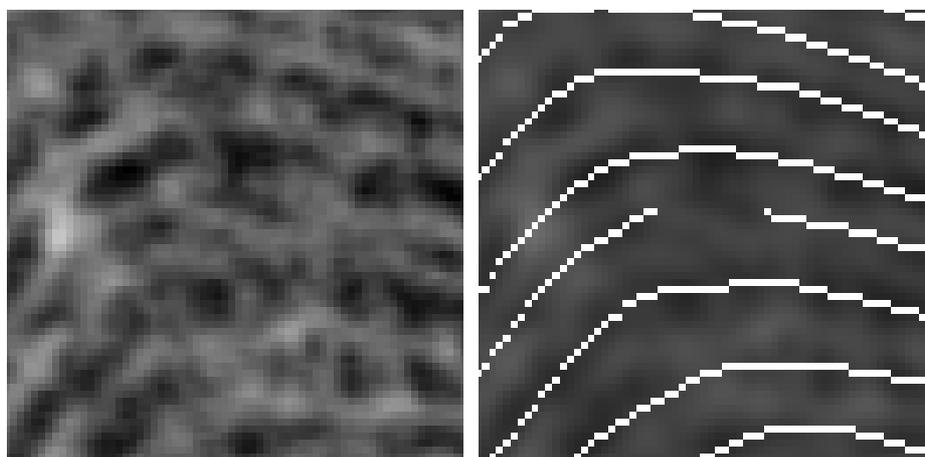


Fig. 4.6 Segment de strate absent

Ces deux erreurs sont en grande partie dues aux fortes perturbations des niveaux de gris dans les zones concernées, et à une diminution locale du contraste entre la zone de strate et la zone d'inter strate.

La qualité de l'estimation des orientations n'est pas à l'origine de cette erreur : au contraire, il est possible d'extrapoler la position des points non détectés ou mal détectés grâce à la carte d'orientation (cf 4.2.2.3).

Enfin, dans certaines zones où les strates subissent de forts changements d'orientation alors que l'image est de très mauvaise qualité, l'image et la carte d'orientation sont toutes deux perturbées. Un phénomène de surdétection du nombre de strates peut alors survenir (Fig. 4.7).

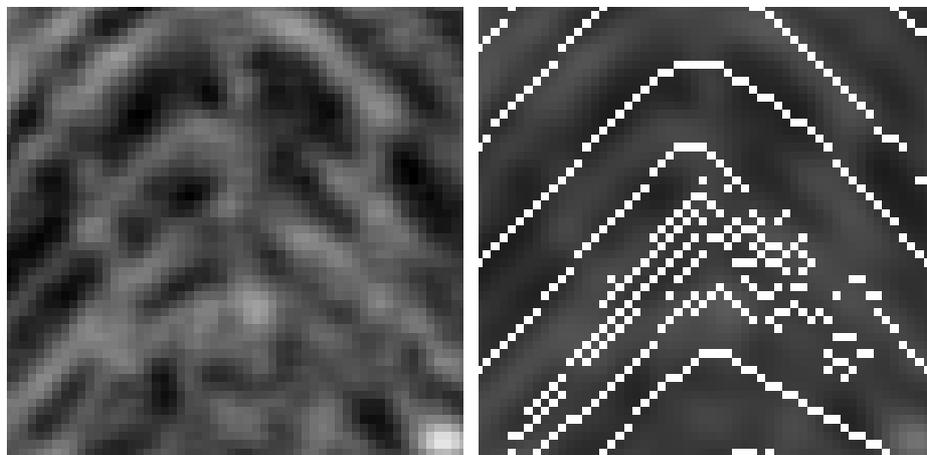


Fig. 4.7 Surdétection de strates

La détection de strates s'effectuant grâce à une recherche des extrema locaux, une élimination des extrema non significatifs (grâce par exemple à l'algorithme de recherche des extrema locaux présenté en Annexe D) permet de diminuer le nombre de ces détections erronées.

Des résultats obtenus sur d'autres parties de l'empilement sont présentés en figures 4.8 et 4.9.

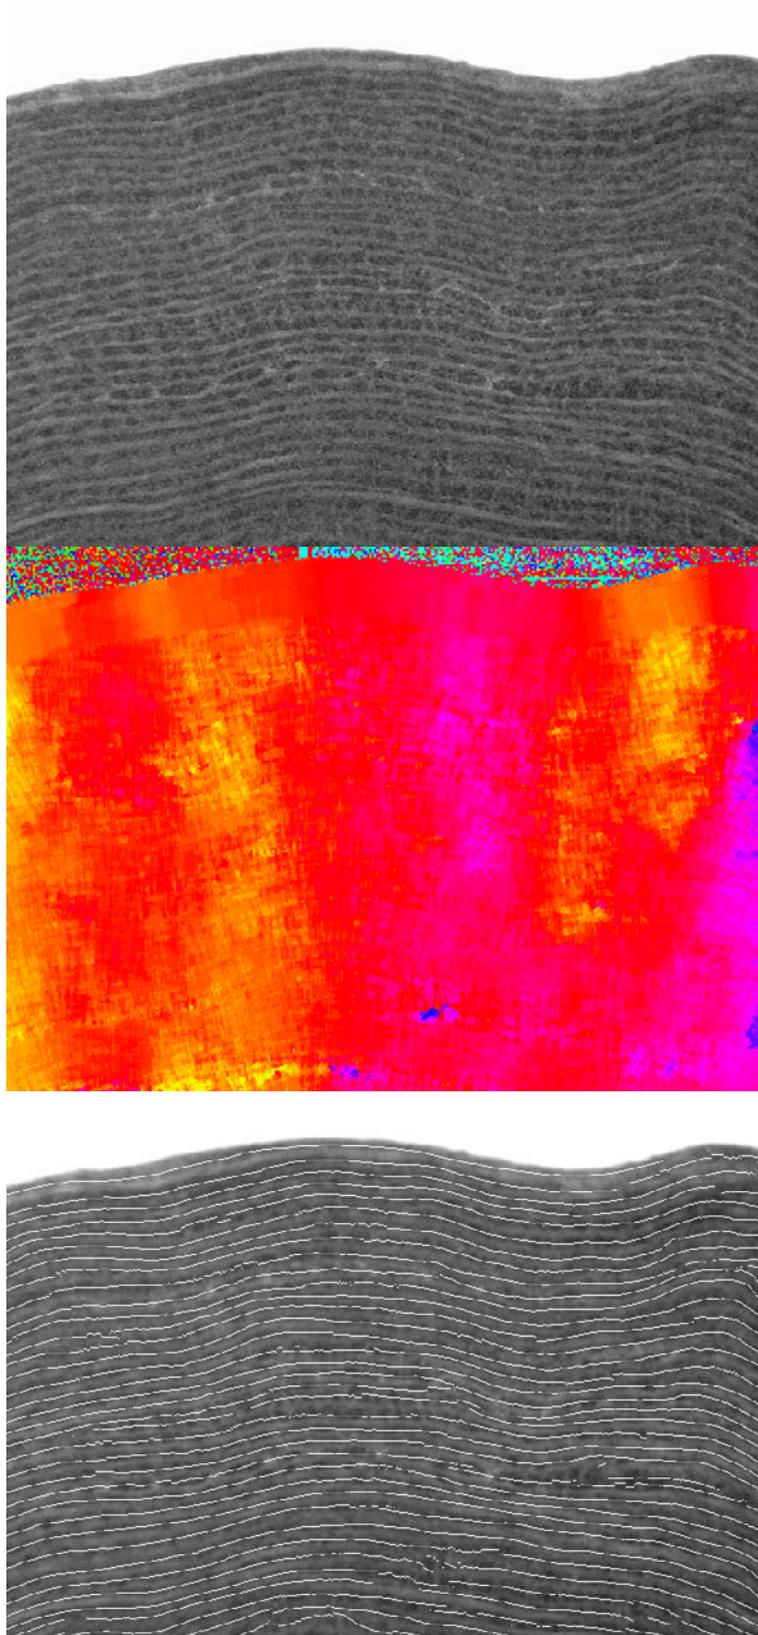


Fig. 4.8 Matériau stratifié, orientation estimée, et strates détectées

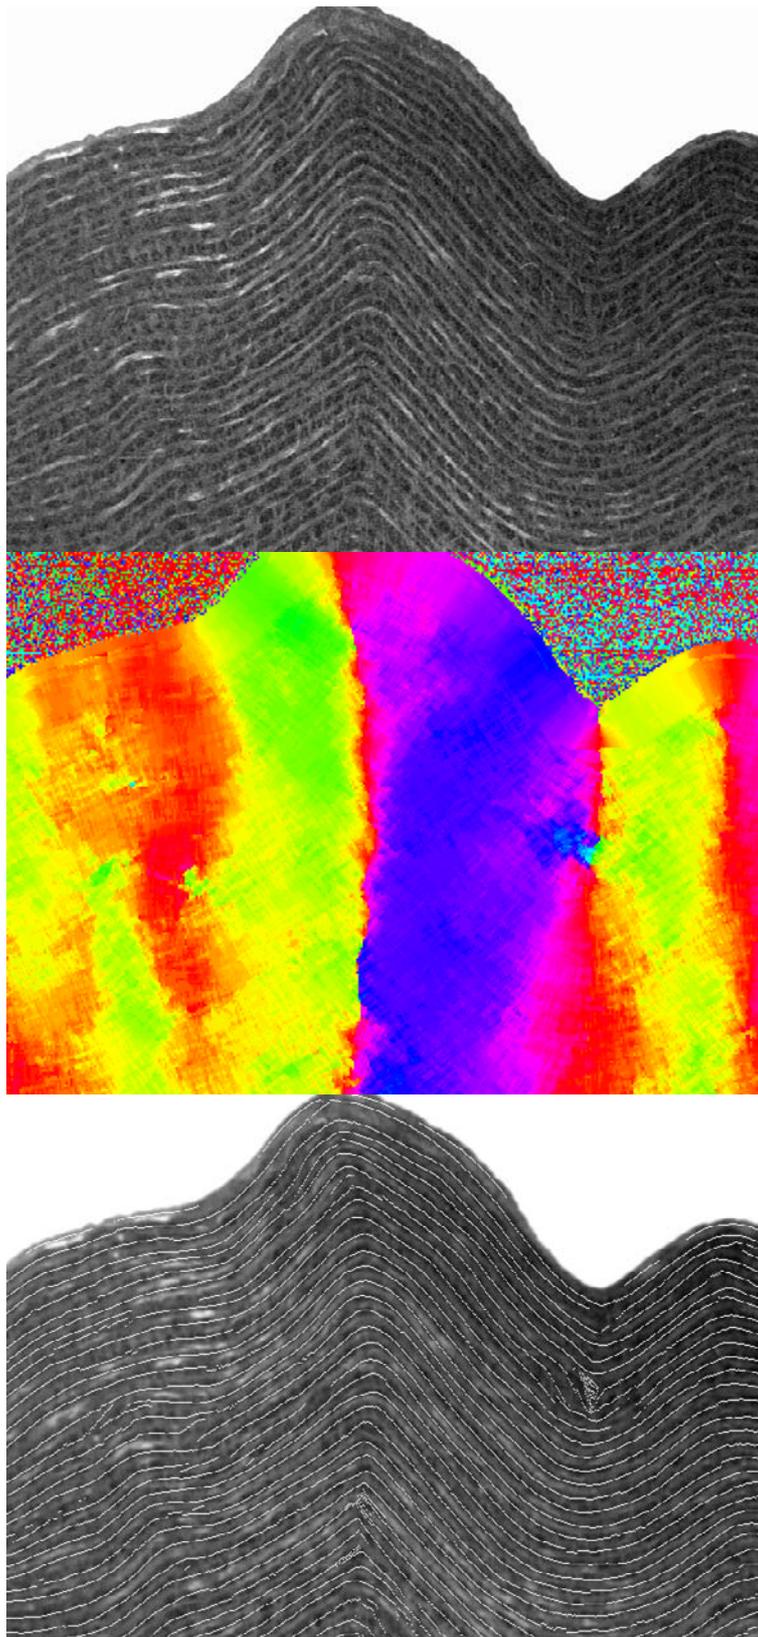


Fig. 4.9 Matériau stratifié, orientation estimée, et strates détectées

4.2.4 Conclusion

L'utilisation de l'opérateur IRON dans cette application nous permet d'estimer l'orientation locale principale en chaque point de l'image, malgré la présence d'une orientation secondaire parasite. L'opérateur IRON est moins sensible aux perturbations que les autres méthodes.

Grâce à la connaissance précise de la carte de l'orientation principale, nous pouvons détecter la position des strates de fibres constituant le matériau. Cette détection permet de mesurer automatiquement les divers paramètres nécessaires à l'établissement d'une caractérisation morphologique du matériau étudié.

Afin de permettre l'utilisation dans le cadre industriel d'une telle méthode de caractérisation du matériau, une étape de post-traitement a été implantée, garantissant la continuité des fibres et la régularité de la distance interstrate.

4.3 Caractérisation de composés métalliques

4.3.1 Contexte

Cette étude concerne l'analyse d'une structure aiguilletée d'un alliage métallique. Nous souhaitons détecter les différentes colonies d'aiguilles ayant la même orientation afin de pouvoir par la suite mesurer les dimensions de chacune de ces colonies.

La mesure de ces dimensions ainsi que le calcul des taux de colonies par rapport aux taux d'aiguilles enchevêtrées est nécessaire à la détermination des propriétés de l'échantillon analysé.

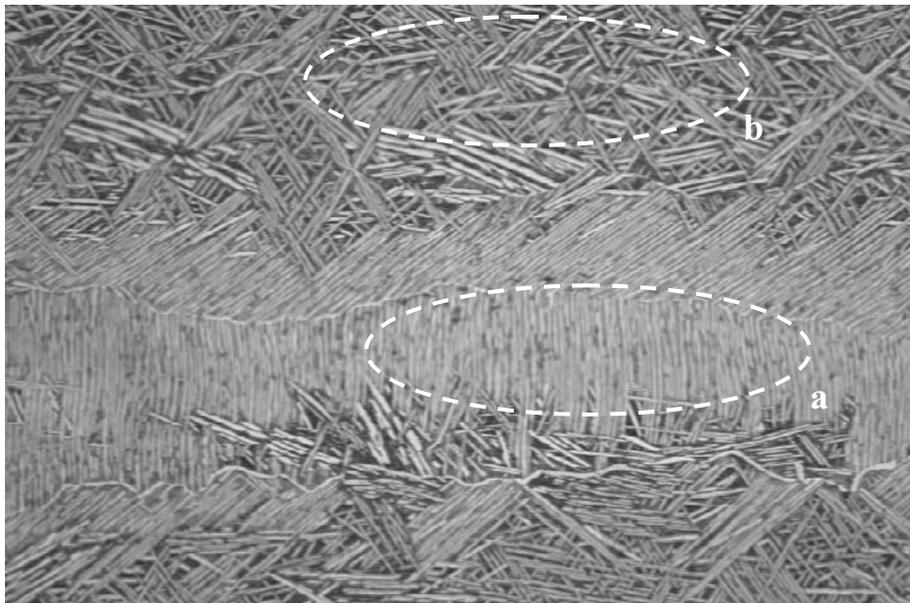


Fig. 4.10 Structure aiguilletée d'un composé métallique

Sur la figure 4.10, la zone (a) est à l'intérieur d'une colonie d'aiguilles quasi verticales, et la zone (b) fait apparaître des aiguilles enchevêtrées.

4.3.2 Solution envisagée

Afin de délimiter les colonies d'aiguilles de même orientation, le calcul de l'orientation locale semble une étape fondamentale.

A travers la segmentation de la carte d'orientation en zones connexes homogènes, il est en effet possible de retrouver les colonies d'aiguilles recherchées.

Suite à des déformations du matériau, il se peut néanmoins que l'orientation des aiguilles varie au sein d'une même colonie. Cette variation, même si elle est lente, peut conduire à des erreurs de segmentation de la carte d'orientation.

Nous proposons donc une alternative à la méthode basée sur la carte d'orientation. Il s'agit de détecter les frontières des colonies grâce à leurs propriétés. En effet, à la frontière d'une colonie, deux orientations sont présentes : celle des aiguilles de la colonie et celle des aiguilles du voisinage de la colonie.

Ainsi, grâce à la détection des points de l'image pour lesquels au moins deux orientations locales existent, nous déterminons la position des frontières des colonies.

4.3.3 Résultats

La validation de cette méthode a été réalisée sur plusieurs échantillons métalliques. Nous présentons des résultats sur un échantillon constitué de nombreuses colonies de petites dimensions (Fig. 4.11).

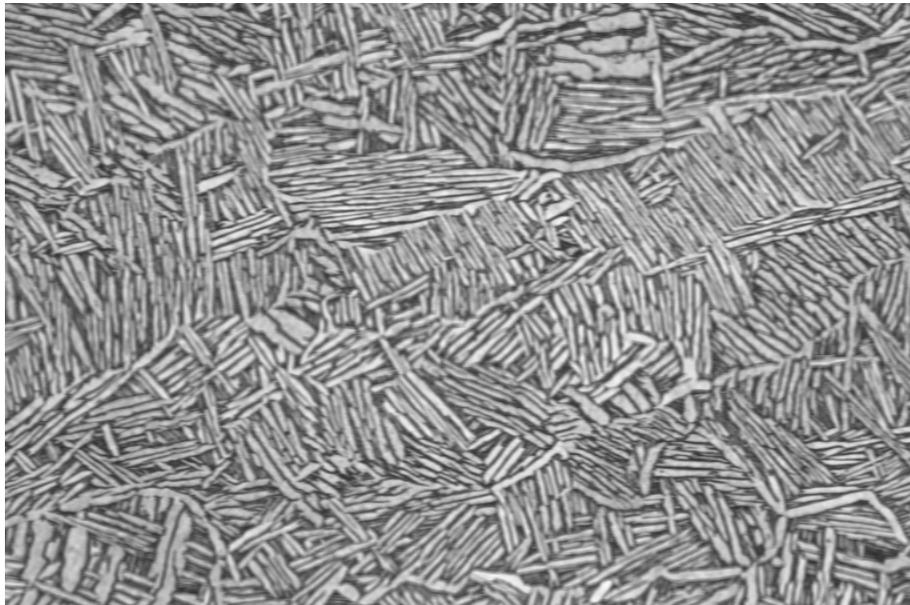


Fig. 4.11 Echantillon métallique

La carte d'orientation obtenue (Fig. 4.12) fait d'ores et déjà apparaître les différentes colonies. Cependant, certaines frontières sont peu précises, voire non détectées.

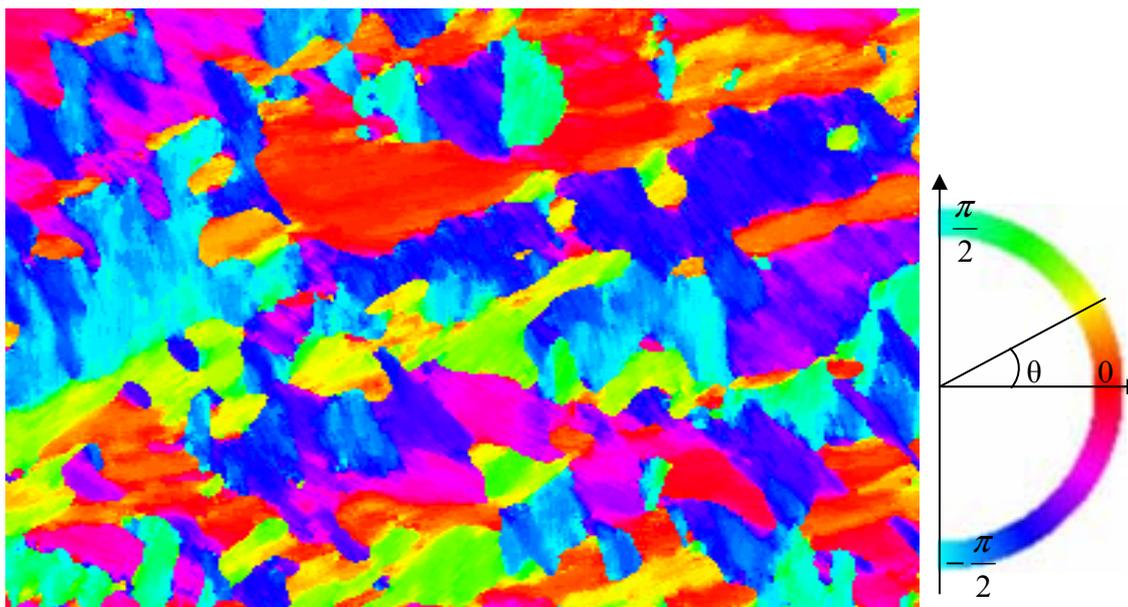


Fig. 4.12 Orientation principale estimée par l'opérateur IRON
(attribut variance, réseau symétrique 11×31)

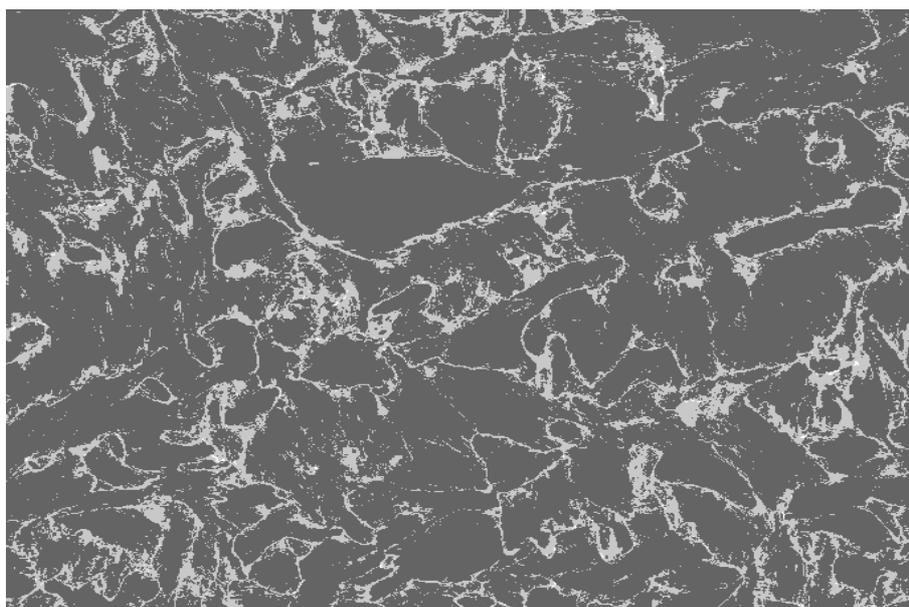


Fig. 4.13 Présence d'orientations locales multiples

Nous dressons la cartographie du nombre d'orientations locales détectées sur l'image par l'opérateur IRON symétrique (Fig. 4.13). L'image est binarisée de manière à faire apparaître en sombre les zones ne présentant qu'une seule orientation locale significative et en clair les zones présentant deux orientations ou plus.

La superposition de cette image (en rouge) avec l'image étudiée montre la correspondance entre les frontières des colonies d'aiguilles et les points pour lesquels nous détectons plusieurs orientations locales (Fig. 4.14).

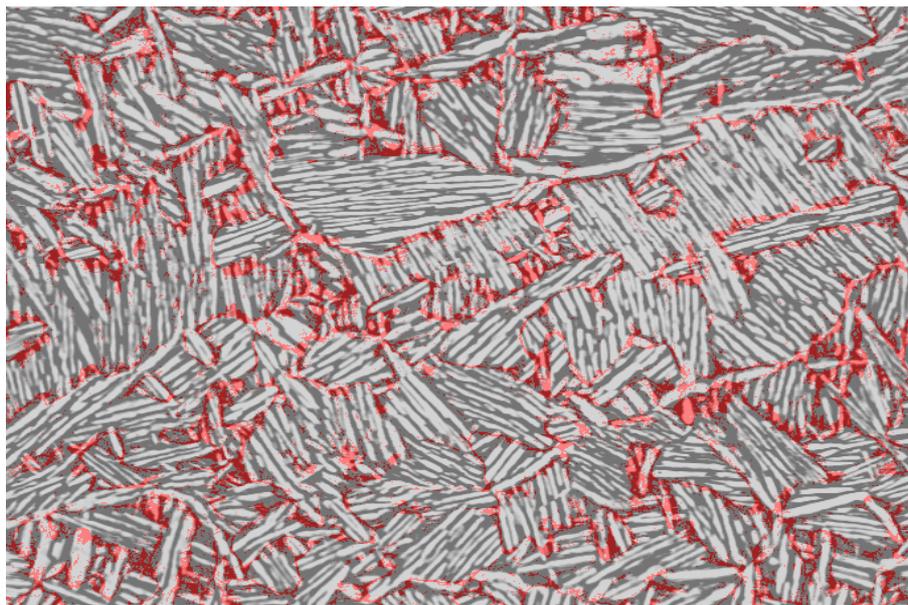


Fig. 4.14 Délimitation des colonies en utilisant le nombre d'orientations

4.3.4 Conclusion

Grâce à la détection des points dont le voisinage présente plus d'une orientation, nous avons proposé une méthode pour la segmentation des colonies d'aiguilles dans ces images d'échantillons métalliques.

Afin d'améliorer encore la qualité d'une telle segmentation, nous pouvons envisager de fusionner les informations issues à la fois de la carte de l'orientation principale et de la carte du nombre d'orientations locales.

4.4 Segmentation en télédétection viticole

4.4.1 Problématique

4.4.1.1 Enjeux de la segmentation de parcelles

La segmentation de parcelles est une étape fondamentale en télédétection viticole. L'automatisation de cette segmentation présente un intérêt particulier pour le contrôle de surfaces. Les organismes intéressés sont par exemple l'Institut National des Appellations d'Origine (INAO) ou l'Office National Interprofessionnel des Vins (ONIVINS).

Elle intéresse également les exploitants et les caves coopératives en tant qu'étape de prétraitement pour délimiter une parcelle avant d'en extraire les caractéristiques intra parcelle. Cette analyse entre dans le cadre de l'agriculture de précision, par exemple pour la détection et la localisation des foyers de maladie ou l'analyse de la vigueur des vignes.

4.4.1.2 Acquisition d'images

Les images utilisées sont issues de la télédétection haute résolution. Les acquisitions sont effectuées par avion, et la résolution au sol ainsi obtenue est de l'ordre de 15cm par pixel (Fig. 4.15). Nous disposons à la fois d'images couleur, et d'images multi spectrales.

En fonction de la résolution et de la taille des parcelles, une image à traiter peut atteindre plusieurs milliers de pixels de côté.

Les images qui sont présentées dans ce chapitre sont issues des vignobles bordelais.

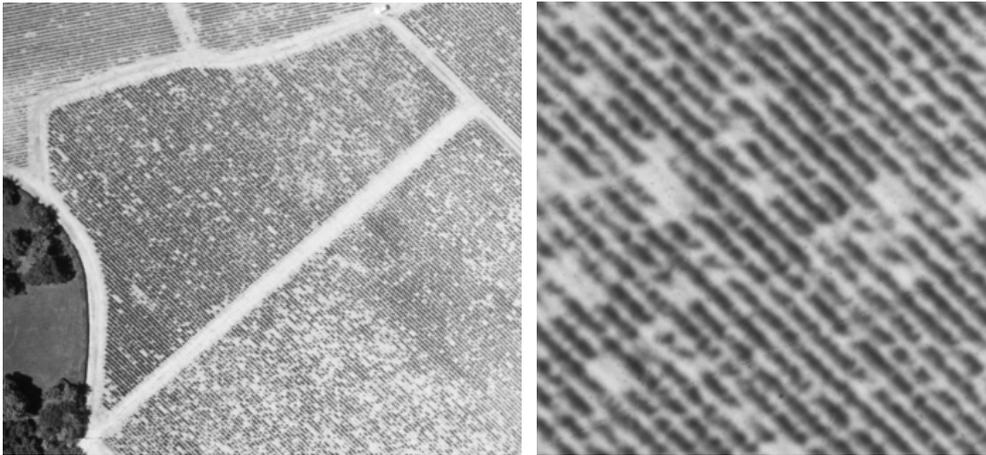


Fig. 4.15 Image de vignoble typique en télédétection haute résolution et extrait de la parcelle centrale (résolution au sol 15cm par pixel)

Les méthodes d'estimation présentées dans ce mémoire s'appliquent à des images en niveaux de gris. De telles images sont obtenues à partir des images couleur ou multi spectrales par une combinaison de différentes bandes spectrales.

Parmi les combinaisons possibles citons le Normalized Difference Vegetation Index (NDVI) et le Ratio Vegetation Index (RVI) qui sont utilisés en agriculture comme indicateurs de la vigueur de la végétation [Rou 74].

4.4.1.3 Méthodes existantes

Les algorithmes de segmentation sont couramment employés en télédétection. Il est possible d'en distinguer trois catégories : les approches statistiques, les algorithmes de division et fusion, et les méthodes de croissance de régions.

Les méthodes statistiques se fondent sur une modélisation conjointe des contenus et des formes des régions. Parmi ces méthodes les modèles markoviens sont souvent privilégiés pour leur flexibilité. La seule contrepartie de ces méthodes statistiques est l'important temps de calcul nécessaire à une segmentation optimale.

Les méthodes de division et fusion sont simples à implanter mais favorisent des régions rectangulaires. De plus, ces méthodes sont sensibles aux réglages des seuils utilisés pour déterminer les paramètres des régions.

Les méthodes de croissance de région sont bien adaptées à la délimitation d'une région dans une image. Da Costa et al. [DaC 04] ont proposé une méthode fondée sur une description texturale de l'image par des filtres de Gabor associée à un algorithme de croissance de région. Le principal inconvénient de cette méthode est son coût calculatoire prohibitif.

Enfin, Rabatel et al. [Rab 05] ont présenté une méthode multi étapes pour la détection non supervisée de parcelles de vignes. Cette méthode combine une description texturale de l'image par matrices de cooccurrence à une étape de pré segmentation par contours géodésiques.

Le besoin d'une approche multi étapes peut s'expliquer par l'absence d'un attribut textural approprié. En effet, si un attribut permet de différencier efficacement les régions de vigne des régions avoisinantes, un simple seuillage doit permettre une bonne délimitation de la région d'intérêt.

4.4.2 Principe

Nous supposons qu'il est possible de différencier les zones de vigne des zones de non vigne grâce aux différences texturales de ces zones.

Les rangs de vigne dans une même parcelle sont parallèles. Dans une même parcelle l'orientation est donc uniforme. L'orientation n'est cependant pas une donnée suffisante pour segmenter les parcelles : en effet un chemin en bordure de parcelle peut avoir la même orientation que les rangs de vigne.

Il existe cependant des différences texturales fondamentales entre les rangs de vigne et les autres zones de l'image. En particulier les parcelles de vignes sont fortement anisotropes : ces zones de l'image présentent une forte homogénéité des niveaux de gris dans la direction des rangs et une forte hétérogénéité dans la direction perpendiculaire.

D'autre part les zones de routes, chemins, bâtiments et de végétation (herbes, arbres...) sont davantage isotropes : l'homogénéité des niveaux de gris dépend peu de l'orientation étudiée.

A partir de ces considérations, nous pouvons déterminer un protocole permettant de déterminer un attribut discriminant les zones de vigne des zones de non vigne.

Cette méthode se compose de quatre étapes :

- déterminer l'orientation des rangs de vigne dans la parcelle et effectuer une rotation de l'image pour que les rangs de vigne soient horizontaux ;
- calculer les valeurs d'homogénéité horizontales et verticales et combiner les valeurs obtenues en un seul attribut ;
- effectuer un seuillage de cet attribut pour segmenter les zones d'intérêt ;
- procéder à des opérations morphologiques afin d'obtenir une délimitation précise de la parcelle sélectionnée.

4.4.3 Mise en oeuvre

4.4.3.1 Orientation de la parcelle et rotation

L'orientation des rangs de la parcelle θ_p est déterminée par le calcul de l'orientation moyenne dans une fenêtre déterminée préalablement par l'utilisateur.

Les orientations sont calculées en utilisant l'opérateur IRON fondé sur l'attribut variance. L'orientation étant uniforme sur la fenêtre étudiée, nous utilisons un réseau de grandes dimensions. Un réseau d'échelle $E = 45$ (soit 63 lignes et 63 points par lignes) a été utilisé

pour déterminer la carte d'orientations (Fig. 4.16). L'orientation moyenne estimée de la parcelle est $\theta_p = -66.3^\circ$.

D'autres méthodes peuvent être utilisées pour estimer l'orientation moyenne des parcelles, par exemple l'opérateur GVOP [DaC 05].

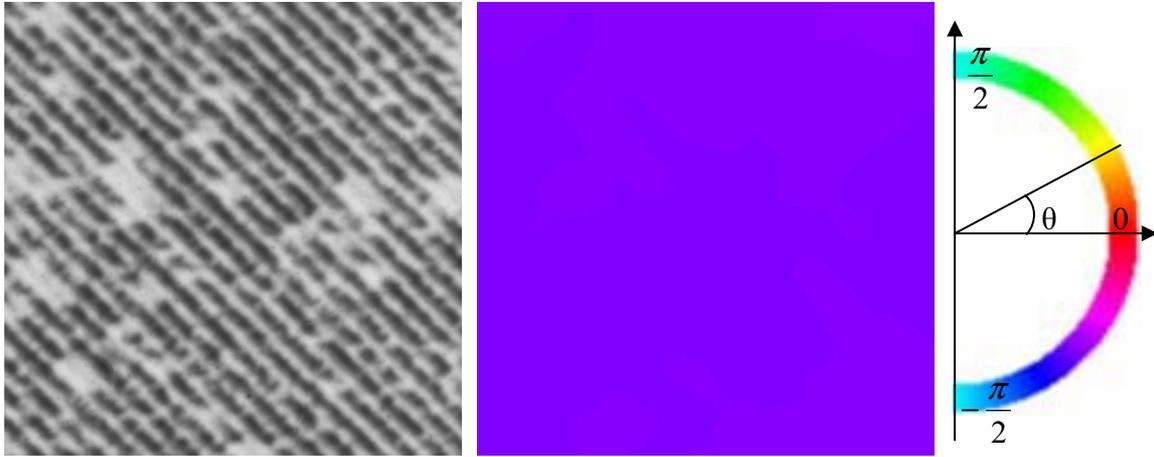


Fig. 4.16 Parcelle de vigne (extrait 256×256),
carte d'orientation estimée par la variance ($E=45$), et palette d'orientation

Afin de conserver un temps de calcul de l'orientation aussi petit que possible, il est préférable que la fenêtre dans laquelle l'orientation de la parcelle est déterminée ne soit pas de dimensions trop importantes. Pour l'utilisateur ceci consiste à sélectionner une fenêtre de la taille désirée à l'intérieur de la zone de référence.

Une fois l'orientation θ_p de la parcelle estimée, nous effectuons une rotation de l'image d'angle $-\theta_p$ de manière à ce que les rangs de vignes soient représentés horizontalement. Cette rotation est réalisée en utilisant l'algorithme en trois passes 1-D utilisé dans notre processus d'estimation de l'orientation [Uns 95].

4.4.3.2 Cartes d'homogénéité et attribut discriminant

Une fois l'image tournée, nous calculons les valeurs d'homogénéité le long d'un réseau asymétrique, dans les directions θ , $\theta + \pi/2$, $\theta + \pi$ et $\theta + 3\pi/2$. Sur cette image tournée, cela revient à calculer l'attribut d'homogénéité dans les quatre directions cardinales de l'image : haut, bas, gauche et droite.

Nous lions l'homogénéité à l'attribut variationnel. En un point (x, y) de l'image et pour un réseau de L lignes et p points par ligne, nous rappelons que cet attribut se calcule par :

$$\Delta_{2\theta}(x, y) = \sum_{j=1}^L \sum_{i=1}^{p-1} |v_{i+1,j,\theta} - v_{i,j,\theta}| \quad (4.3)$$

où les valeurs $v_{i,j,\theta}$ représentent les valeurs de niveau de gris des points du réseau orienté d'angle θ .

Cet attribut mesure un "désordre" le long des lignes du réseau. Une forte homogénéité se traduit donc par une valeur de Δ_2 faible.

Après rotation inverse des résultats, nous obtenons donc quatre cartes fournissant les différentes valeurs de l'attribut variationnel en chaque point (x, y) de l'image : $\Delta_{2\theta}$, $\Delta_{2\theta+\pi/2}$, $\Delta_{2\theta+\pi}$ et $\Delta_{2\theta+3\pi/2}$.

Notons que les cartes $\Delta_{2\theta}$ et $\Delta_{2\theta+\pi}$ (respectivement $\Delta_{2\theta+\pi/2}$ et $\Delta_{2\theta+3\pi/2}$) sont identiques à un décalage horizontal près (resp. vertical) du fait de la position du réseau par rapport à point (x, y) étudié.

L'utilisation de quatre réseaux asymétriques au lieu de deux réseaux symétriques nous permet d'obtenir une segmentation plus précise des bords de la parcelle.

Par exemple, sur les figures 4.17-e et 4.17-f nous observons que les valeurs de $\Delta_{2\theta+\pi/2}$ restent élevées quelques pixels après la limite de la parcelle alors que les valeurs de $\Delta_{2\theta+3\pi/2}$ chutent dès la limite de la parcelle. Le phénomène inverse se produit à la limite inférieure de la parcelle.

Nous pouvons remarquer un comportement équivalent à l'horizontale pour les cartes $\Delta_{2\theta}$ et $\Delta_{2\theta+\pi}$ (Fig. 4.17-b et Fig. 4.17-c).

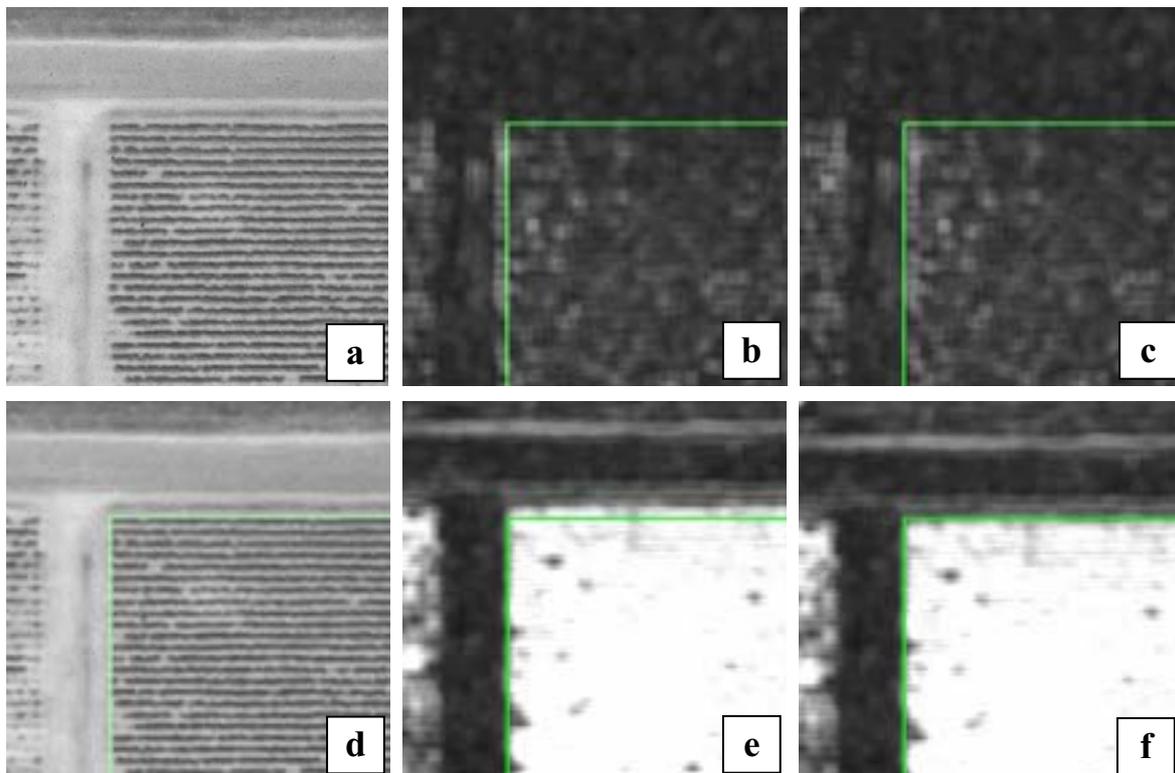


Fig. 4.17 Parcelle de vigne (a), délimitation souhaitée de la parcelle (d) et cartes d'attribut correspondantes $\Delta_{2\theta}$ (b), $\Delta_{2\theta+\pi}$ (c), $\Delta_{2\theta+\pi/2}$ (e), $\Delta_{2\theta+3\pi/2}$ (f)

Afin de minimiser cet effet de bord, nous devons estimer les cartes d'homogénéité sur des réseaux de dimensions réduites. A contrario, nous devons conserver une échelle d'analyse suffisante pour ne être trop sensible aux irrégularités de la végétation.

Au vu des cartes d'attribut précédentes, nous remarquons que les éléments qui discriminent le mieux la parcelle de ses alentours sont les valeurs calculées dans les directions perpendiculaires aux rangs de vigne. Dans notre exemple, le choix idoine serait $\max(\Delta_{2\theta+\pi/2}, \Delta_{2\theta+3\pi/2})$.

Les cartes $\Delta_{2\theta}$ et $\Delta_{2\theta+\pi}$ ne permettent pas de délimiter les parcelles de vigne par rapport aux routes et aux chemins (Fig. 4.17-b et Fig. 4.17-c) car, dans la direction des rangs de vigne, l'homogénéité est forte dans les deux cas.

Ces deux cartes ont cependant une utilité dans la segmentation des parcelles de vigne. En particulier $\Delta_{2\theta}$ et $\Delta_{2\theta+\pi}$ présentent de faibles valeurs partout sauf sur certains éléments extérieurs à la vigne, comme par exemple les arbres (Fig. 4.18-b).

En effet l'hétérogénéité des niveaux de gris des arbres est importante quelle que soit la direction observée. Par conséquent ils seraient considérés comme de la vigne à partir des indications des cartes $\Delta_{2\theta+\pi/2}$ et $\Delta_{2\theta+3\pi/2}$ (Fig. 4.18-c).

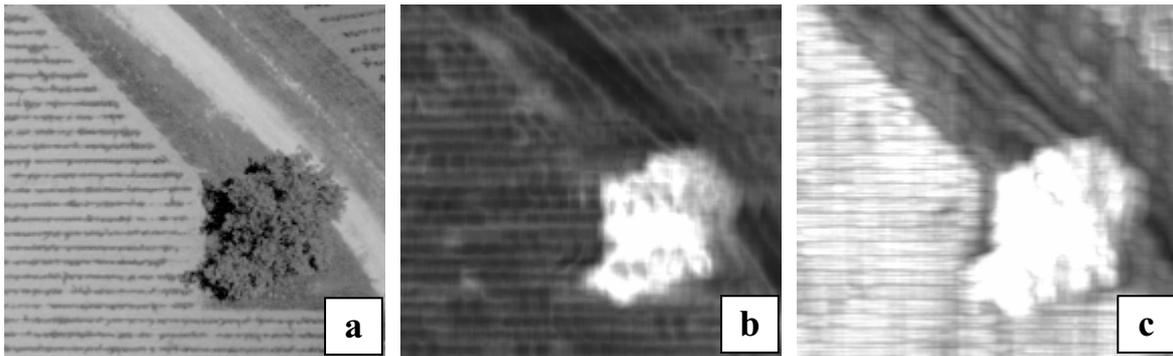


Fig. 4.18 Arbre en limite de parcelle (a), attribut $\min(\Delta_{2\theta}, \Delta_{2\theta+\pi})$ (b), attribut $\max(\Delta_{2\theta+\pi/2}, \Delta_{2\theta+3\pi/2})$ (c)

Pour prendre en compte les considérations précédentes, nous établissons un attribut textural composite C_v permettant de distinguer les zones de vigne du reste de l'image :

$$C_v(x, y) = \left| \max(\Delta_{2\theta+\pi/2}, \Delta_{2\theta+3\pi/2}) - \min(\Delta_{2\theta}, \Delta_{2\theta+\pi}) \right| \quad (4.4)$$

Afin de réduire le temps de calcul, nous effectuons la combinaison des différentes valeurs nécessaires pour obtenir C_v avant la rotation inverse des cartes d'attribut. Il suffit donc d'effectuer une seule rotation inverse au lieu de quatre.

La figure 4.19 présente les résultats obtenus sur les images précédentes : nous pouvons désormais distinguer aisément la parcelle de vigne de l'herbe, des chemins et des arbres.

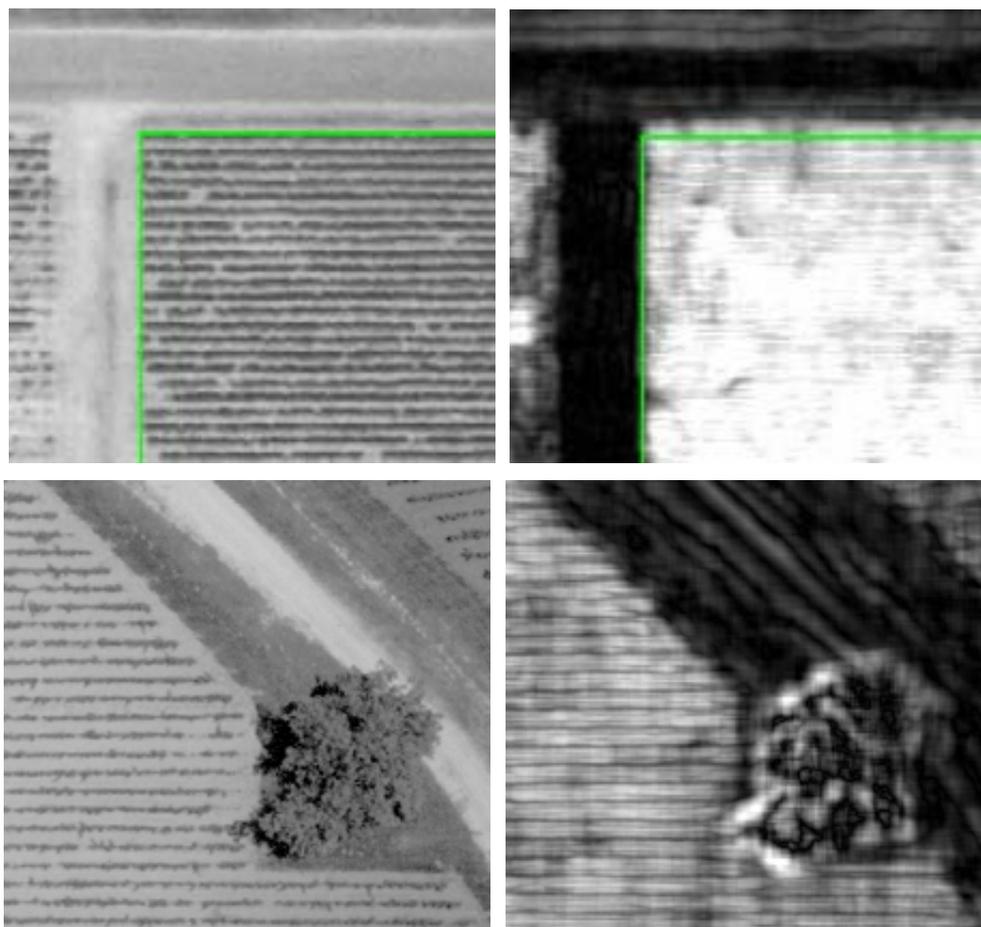


Fig. 4.19 Images de test (gauche) et attribut $C_v(x,y)$ (droite)

4.4.3.3 Seuillage de l'attribut discriminant

L'attribut C_v permet de différencier les zones de vigne des zones où la vigne est absente. Un double seuillage de cet attribut permet de classer chaque pixel de l'image dans l'une de ces deux catégories.

Les seuils sont fixés en se basant sur la distribution de C_v à l'intérieur de la zone d'initialisation sélectionnée par l'utilisateur :

$$\overline{C_{vref}} - \sigma_{C_{vref}} \leq C_v(x,y) \leq \overline{C_{vref}} + \sigma_{C_{vref}} \quad (4.5)$$

$\overline{C_{vref}}$ représente la moyenne et $\sigma_{C_{vref}}$ représente l'écart type de C_v (estimé par la racine carrée de l'écart quadratique moyen) à l'intérieur de la zone de référence.

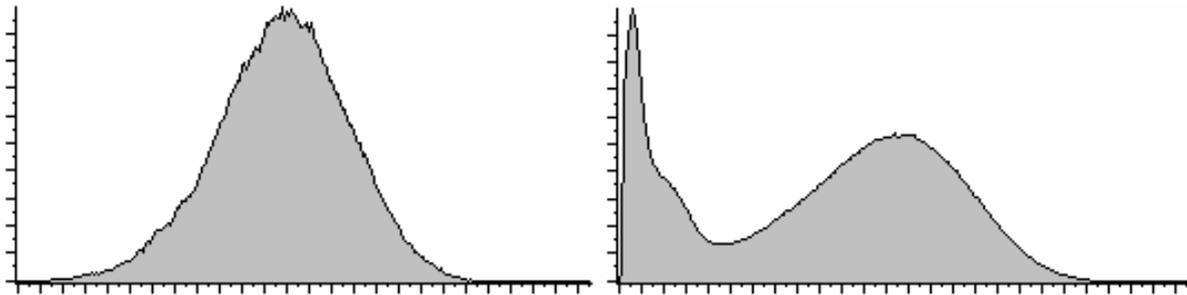


Fig. 4.20 Histogramme de $C_v(x,y)$ sur la zone d'initialisation (gauche) et sur toute l'image (droite)

La distribution de C_v à l'intérieur de cette zone de référence est quasi-gaussienne. L'histogramme associé (Fig. 4.20) permet bien de différencier la parcelle du reste de l'image (faibles valeurs à gauche de l'histogramme).

4.4.3.4 Opérations morphologiques

Les opérations morphologiques opérées sur la segmentation de l'image sont les suivantes :

- remplissage des trous dans la zone segmentée,
- extraction des zones connexes à la zone d'initialisation,
- régularisation morphologique afin de lisser les bords de la parcelle.

Les résultats de ces opérations morphologiques sont présentés en partie 4.4.3.5, avec un récapitulatif des différentes étapes du traitement.

4.4.3.5 Processus complet de segmentation

Nous présentons ici à titre d'exemple le processus complet de segmentation opéré sur la parcelle de la figure 4.15.

La première étape de la segmentation est réalisée par l'utilisateur et consiste à sélectionner une zone rectangulaire dans la parcelle à segmenter (Fig. 4.21-a). Le choix de cette zone de référence n'est pas critique à partir du moment où elle est de taille suffisante pour déterminer l'orientation des rangs de vigne et où elle est représentative de l'ensemble de la parcelle. En tenant compte de la résolution des images et de la taille des parcelles, la première condition est très facilement vérifiée. La deuxième condition est vérifiée dès que la taille de la zone de référence représente une fraction non négligeable de l'ensemble de la parcelle.

A partir de cette zone de référence, nous estimons l'orientation des rangs de vigne dans la parcelle puis nous effectuons la rotation de l'image de manière à ramener les rangs de vigne à l'horizontale (Fig. 4.21-b).

Puis, à l'aide d'un réseau asymétrique de 15 lignes et 15 points par ligne, nous calculons l'attribut C_v sur l'ensemble de l'image (Fig. 4.21-c). L'échelle du réseau utilisé est liée à la distance séparant chaque rang de vigne (environ 10 pixels). Nous effectuons la rotation inverse nécessaire pour faire coïncider la carte d'attribut avec l'image initiale (Fig. 4.21-d).

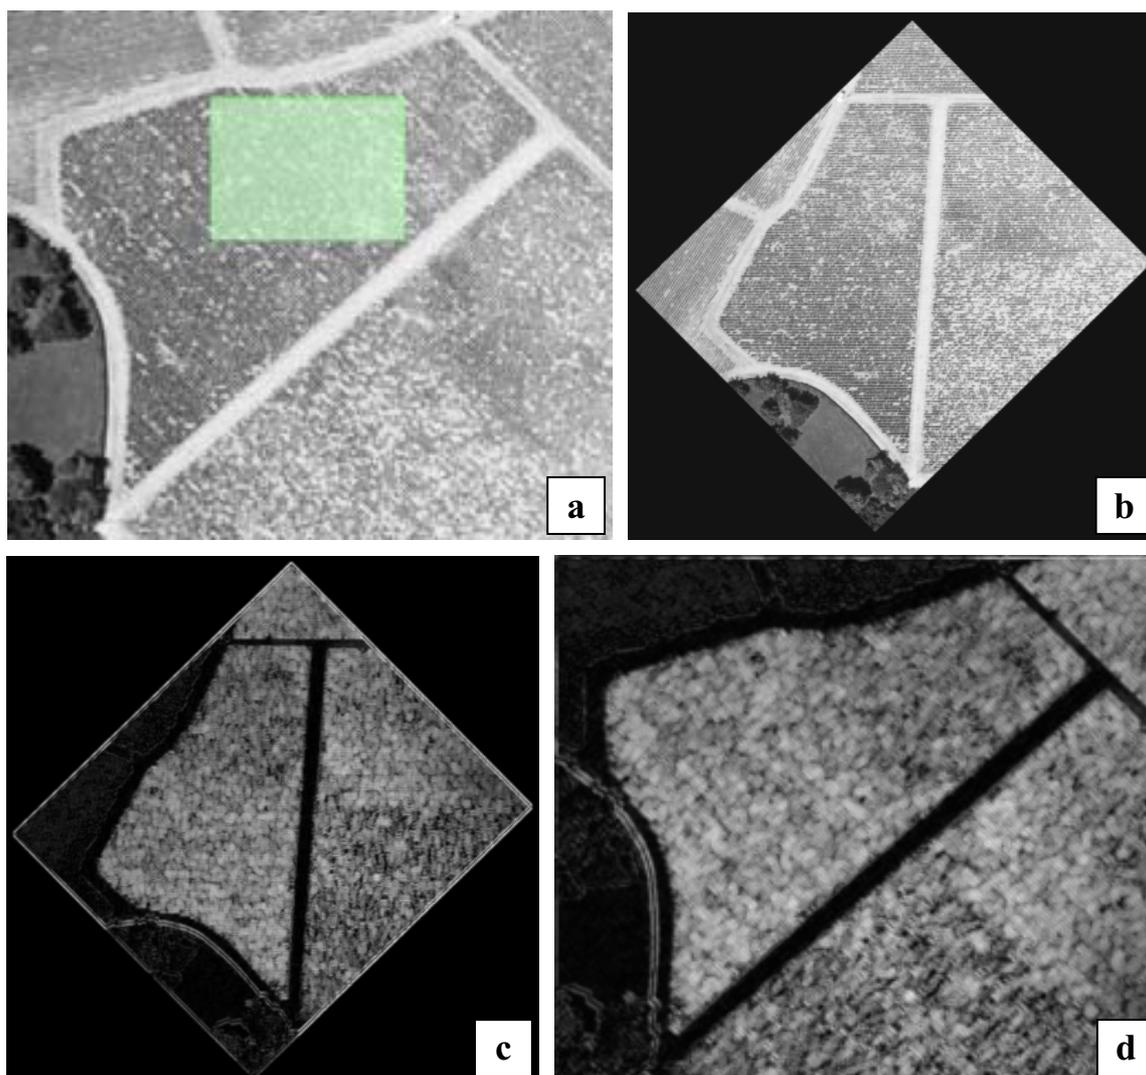


Fig. 4.21 Sélection de la zone de référence (a), rotation de l'image (b), calcul de l'attribut C_v (c), attribut C_v après rotation inverse (d).

Nous effectuons alors la première segmentation de l'image d'attribut (Fig. 4.22-a).

Nous procédons enfin aux opérations morphologiques nécessaires à la régularisation de la parcelle, à savoir : un remplissage des trous apparaissant à l'intérieur de la zone segmentée (Fig. 4.22-b), la sélection de la zone connexe à la zone de référence (Fig. 4.22-c) et pour finir une fermeture afin de lisser les limites de la parcelle (Fig. 4.22-d). L'élément structurant utilisé est de dimensions 16×16 . Les images de la figure 4.22 correspondent à la superposition de l'image initiale avec les différents masques de segmentation.

Au cours de ces étapes finales de la segmentation, nous pouvons observer que d'autres parcelles ayant la même orientation sont initialement détectées (Fig. 4.22-a). Ceci justifie la sélection de la zone connexe à la zone de référence.

Le résultat final correspond à la réalité terrain : il ne présente aucune zone manquante, et les limites de la parcelle sont lisses, à l'exception des endroits où il manque un pied de vigne en bordure de parcelle. Notons également que la zone de vigne de faible vigueur dans le coin inférieur droit de la parcelle a été correctement détectée.

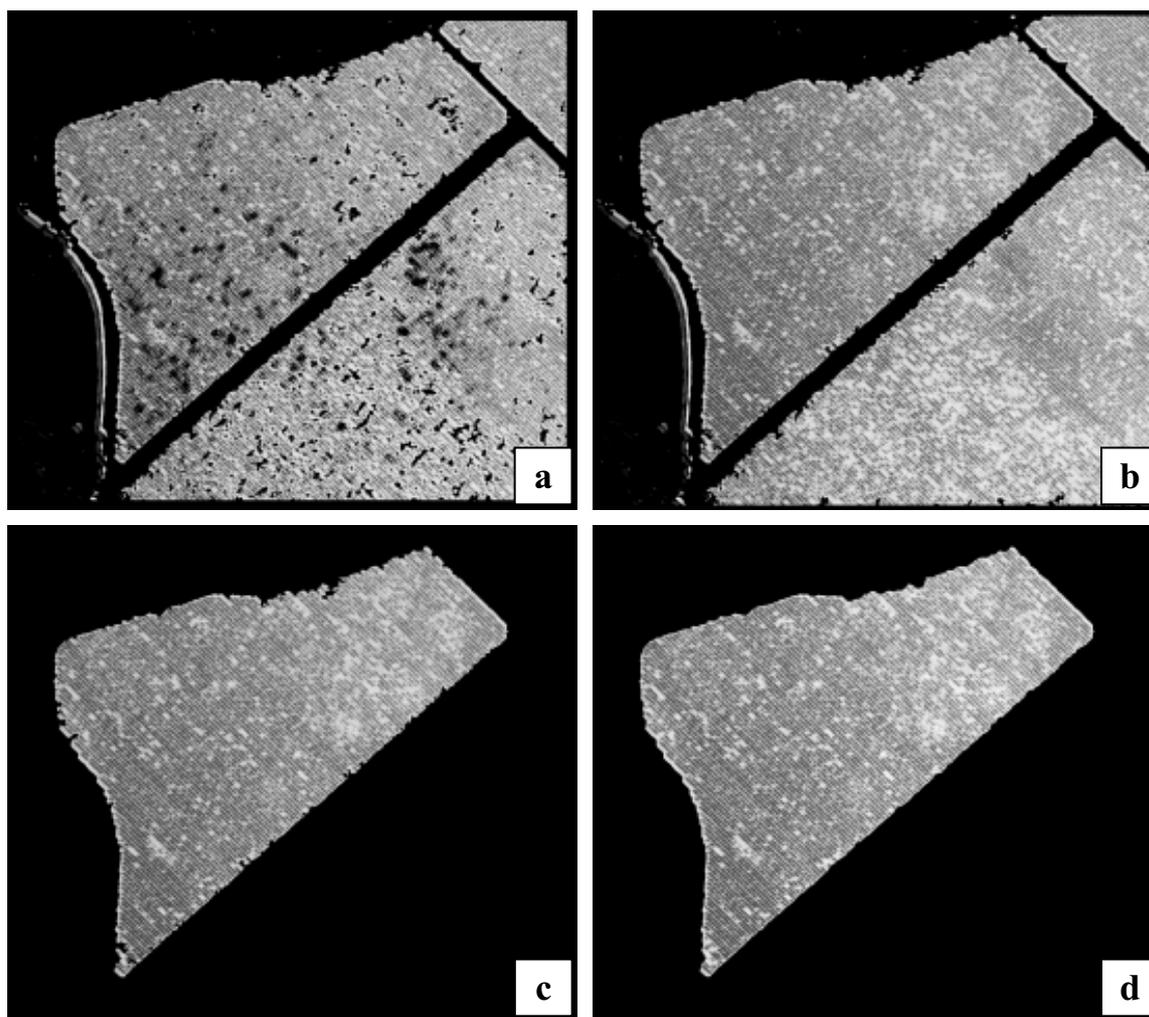


Fig. 4.22 Seuillage de l'attribut C_v (a), remplissage des trous (b), sélection de la zone connexe à la zone d'initialisation (c), lissage des limites de la parcelle par morphologie mathématique (d)

4.4.4 Discussion

4.4.4.1 Résultats complémentaires

Cet algorithme de segmentation a été testé sur un grand nombre d'images de la base de données. Nous présentons ici quelques résultats complémentaires afin d'exposer les avantages et les limites de cette méthode.

Sur les images de la figure 4.23, les parcelles sélectionnées sont correctement délimitées et séparées du reste de l'image. L'algorithme n'est pas sensible aux irrégularités de la végétation, qu'elles soient causées par l'absence de quelques pieds de vigne ou par une vigueur plus faible dans certaines zones de dimensions réduites.

Nous notons également que la méthode s'adapte à différents types de végétation. La présence de terre nue ou d'herbe entre les rangs ne perturbe pas le processus de segmentation,

pas plus que les variations de distance inter rangs. Cette bonne capacité d'adaptation est liée au fait que nous avons formulé peu d'hypothèses pour choisir les paramètres de l'opérateur.

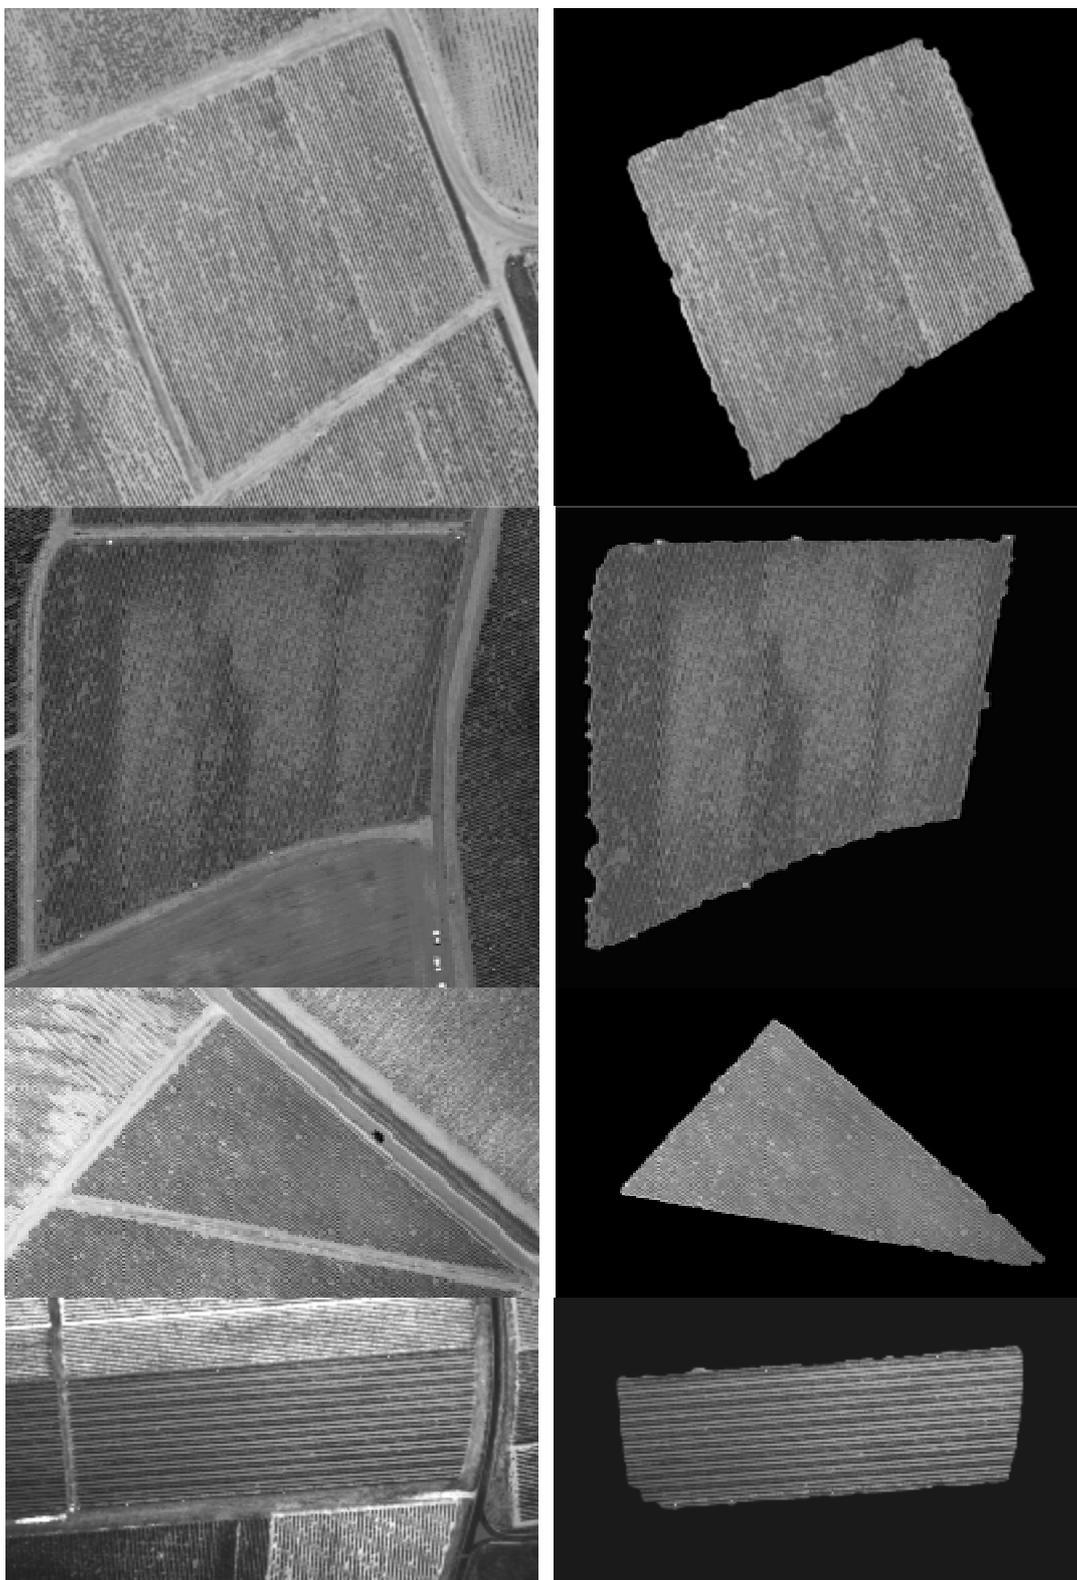


Fig. 4.23 Exemples de parcelles de vigne et résultats de segmentation correspondants. (utilisation d'un réseau asymétrique 15×15 et fermeture 16×16)

4.4.4.2 Problèmes rencontrés

Dans certaines situations, la segmentation de la parcelle n'est pas satisfaisante :

- lorsque les zones de la parcelle présentent une vigueur très faible (ce qui correspond aux zones atteintes par la maladie, aux jeunes pieds, ou au début de la saison végétative) les valeurs de C_v sont plus faibles que dans le reste de la parcelle. Certaines zones saines en bordure de parcelle peuvent alors se retrouver isolées du reste de la parcelle par les zones de faible vigueur (Fig. 4.24-b).

- certains chemins en bord de parcelle peuvent être détectés comme des rangs de vigne. Ceci se produit surtout lorsque des tracteurs enjambeurs ou des machines à vendanger sont utilisés. Ces machines creusent des ornières espacées de la distance inter rang, parallèlement aux rangs de vigne. L'herbe pouvant pousser entre les ornières accentue encore la confusion, et dans les cas les plus défavorables, des parcelles voisines peuvent être agrégées à la parcelle étudiée (Fig. 4.24-d).

- la présence de motifs orientés très marqués et proches de la parcelle étudiée peut influencer la segmentation. Par exemple sur la figure 4.24-f, les bandes blanches de la route perturbent la segmentation de la parcelle.

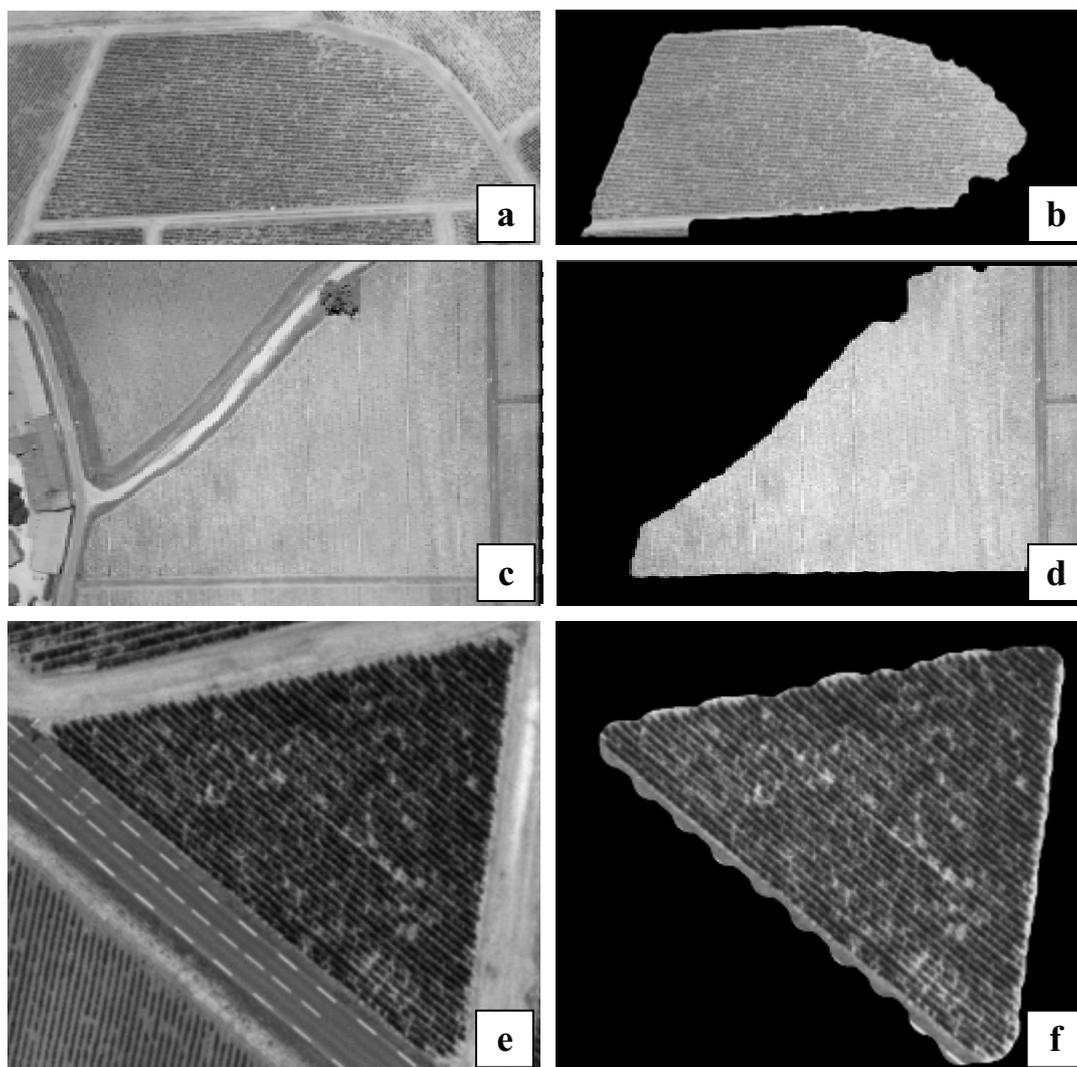


Fig. 4.24 Parcelles de vignes et segmentation correspondante (présence d'erreurs de segmentation dans certaines situations)

4.4.4.3 Temps d'exécution

Par rapport à d'autres méthodes non supervisées ou supervisées [DaC 04], le temps de calcul est diminué de façon significative. Alors que sur la plupart des images les algorithmes antérieurs avaient un temps d'exécution d'au moins une minute, notre méthode nécessite, sur les mêmes images, un temps d'exécution inférieur à 10 secondes (tableau 4.1).

Les algorithmes ont été implantés en langage C, et testés sur un ordinateur de bureau équipé d'un processeur cadencé à 2.0GHz et de 1Go de mémoire vive.

Image 1829×1605	
Estimation de l'orientation des rangs de vigne	4 s
Rotations (directe et inverse)	3 s
Calcul des cartes d'homogénéité et de C_v	2 s
Seuillage et post-processing	< 1 s
Total	< 10 s

Tab. 4.1 Temps d'exécution de l'ensemble du processus

De telles performances rendent possible l'intégration de cet algorithme dans une chaîne de traitement complète, de l'acquisition à la génération de cartes de management. Cet algorithme a par exemple sa place en tant qu'étape préliminaire à la détection de rangs [Bob 03].

4.4.5 Bilan

Nous avons proposé dans cette partie une nouvelle méthode de délimitation automatique de parcelles de vignes dans des images de télédétection haute résolution.

Cette méthode repose sur une description texturale des rangs de vigne. En utilisant notre réseau orienté, nous avons défini un nouvel attribut textural fondé sur la mesure de l'écart à un modèle de texture orientée.

La segmentation de cet attribut textural permet de discriminer efficacement les pixels de vigne de la parcelle étudiée du reste de l'image. Les résultats de segmentation sont satisfaisants.

Dans les perspectives d'évolution de cette application, nous envisageons de préciser la définition de notre attribut discriminant afin de le rendre moins sensible aux structures orientées à forte énergie bordant les parcelles comme par exemple les marquages au sol du réseau routier.

Nous mènerons également une étude sur le choix de la combinaison spectrale (NDVI...) appropriée à la différenciation entre l'herbe et les rangs de vigne, et limitant les variations dues aux changements des conditions d'éclairage.

La dernière étape sera l'intégration de ce module de segmentation à l'intérieur d'une chaîne de traitement de l'image. L'ensemble sera alors relié à un Système d'Information Géographique.

4.5 Conclusion

A travers les applications présentées dans ce chapitre, nous avons confirmé les performances de l'opérateur IRON confronté à des cas concrets.

Appliqué à des images de matériaux composites stratifiés, l'opérateur IRON est capable d'estimer précisément l'orientation locale principale en tout point de l'image, même lorsqu'une orientation secondaire perturbe la mesure.

La connaissance de la carte d'orientation résultante a permis d'établir une caractérisation morphologique du matériau composite que nous avons étudié.

L'opérateur IRON offre également la possibilité de mesurer aisément des orientations multiples. Grâce à la détection des points dont le voisinage fait apparaître plus d'une orientation, nous avons pu détecter les frontières de colonies d'aiguilles dans des échantillons métalliques, et ce afin d'en déterminer les propriétés morphologiques.

Enfin, la mesure de l'écart entre l'image et un modèle de voisinage orienté permet d'établir un attribut textural qui facilite la segmentation d'images orientées. Cette segmentation a été mise en pratique dans le cadre de la délimitation de parcelles viticoles.

Ainsi, la simplicité de réglage de l'opérateur IRON et sa grande flexibilité rendent son utilisation particulièrement intéressante pour un grand nombre d'applications concernant les images orientées.

Notons en particulier que le procédé de détermination de l'orientation locale principale d'une image par l'opérateur IRON est actuellement utilisé par le laboratoire de caractérisation des matériaux composites de la société Snecma Propulsion Solide (Groupe Safran).

Conclusion

Dans ce mémoire, nous avons proposé un nouvel opérateur d'estimation des orientations locales multiples.

Cet opérateur orienté se fonde sur une définition de l'orientation reposant sur des considérations perceptuelles. Pour une orientation donnée, l'opérateur consiste en un réseau de lignes le long desquelles nous mesurons l'adéquation de l'image à un modèle de voisinage orienté.

L'opérateur IRON répond aux objectifs et aux contraintes que nous nous étions fixés initialement :

- sur une image non bruitée il fournit une estimation non biaisée de l'orientation,
- il présente une bonne immunité au bruit quelle que soit l'échelle d'analyse,
- il est capable de détecter plusieurs orientations,
- sa sélectivité angulaire est meilleure que celle des autres opérateurs orientés,
- il n'est pas sensible aux variations de la période locale de l'image,
- il permet une estimation des orientations aussi bien à grande échelle qu'à petite échelle
- enfin, l'implantation rapide de notre opérateur lui confère un coût calculatoire réduit.

L'opérateur est simple à régler puisque seuls les paramètres de géométrie et l'attribut calculé sur le réseau doivent être déterminés par l'utilisateur.

Les dimensions du réseau de lignes déterminent le voisinage étudié et donc l'échelle d'analyse de l'opérateur, dont dépendent à la fois la robustesse au bruit et le caractère local de l'estimation. L'épaisseur du réseau influe sur sa sélectivité angulaire et le choix de la symétrie du réseau par rapport au point d'intérêt permet une estimation des orientations locales modulo π ou modulo 2π .

Le choix de l'attribut calculé le long des lignes du réseau est, quant à lui, déterminé par l'application envisagée :

- la variance présente une bonne immunité au bruit blanc et convient à la plupart des situations,
- la variationnelle privilégie la sélectivité angulaire,
- l'attribut robuste MAD est le moins sensible aux bruits impulsifs,
- enfin l'attribut fondé sur un modèle de modulation affine permet de s'affranchir des éventuelles modulations d'amplitude de l'image.

Pour faciliter encore le réglage des paramètres, une implantation adaptative en échelle de l'opérateur IRON a été proposée, permettant d'estimer l'échelle réalisant le meilleur compromis entre la robustesse au bruit et la précision de l'estimation de l'orientation locale.

Ainsi l'opérateur IRON, capable d'estimer précisément les orientations locales dans un grand nombre de situations difficiles, présente une alternative avantageuse aux autres méthodes d'estimation des orientations.

L'opérateur IRON a été appliqué avec succès à des problèmes d'analyse de matériaux composites et de composés métalliques, pour lesquels la connaissance de l'orientation des éléments constituant le matériau permet d'en extraire les principales informations structurelles.

Le processus de mesure de l'adéquation de l'image à un modèle de voisinage orienté nous a également permis d'élaborer un attribut discriminant une zone d'une image orientée de son environnement. Nous avons ainsi proposé une méthode de délimitation automatique de parcelles viticoles.

Enfin, il apparaît intéressant de poursuivre cette démarche selon les deux axes suivants :

- le premier consiste à développer et étudier de nouveaux attributs d'homogénéité. Ces nouveaux attributs peuvent être une combinaison de ceux présentés dans ce mémoire, en tirant parti de leurs avantages respectifs. Ils peuvent également constituer une nouvelle mesure de l'écart au modèle de voisinage orienté.

- le second axe de développement est l'application de notre méthode à l'étude de données tridimensionnelles. Bien qu'une approche multi 2-D soit envisageable, une telle étude requiert une définition de la notion d'orientation en trois dimensions, certainement basée sur l'étude des surfaces d'iso niveau. Une approche purement 3-D est également possible, mais un tel opérateur orienté devra balayer toute la sphère des orientations. Le problème de complexité calculatoire devient alors contraignant et constitue la principale difficulté à résoudre lors de l'extension 3-D.

Annexes

Annexe A : Changement d'échelle et lissage des orientations

Dans une image d'orientation régulière, il est possible de déterminer l'orientation globale à partir des orientations locales. Le but des méthodes présentées ci-après est d'agrèger les orientations locales obtenues à une échelle donnée de manière à obtenir une information à une échelle plus large. Si on conserve la même échelle d'analyse, ces méthodes permettent également un lissage des orientations. Ces méthodes permettent de calculer la moyenne ou l'espérance d'un ensemble de variables circulaires, et plus particulièrement d'un champ d'orientations.

Algorithme de Rao

Rao [Rao 90][Che 02] décrit une procédure complète pour l'estimation de l'orientation locale en lissant les données obtenues par le calcul des gradients sur l'image.

Cet algorithme suit les étapes suivantes :

- lissage de l'image étudiée par une gaussienne de variance σ_1
- calcul des gradients horizontaux et verticaux sur l'image. Pour chaque point (i, j) de l'image, la norme ρ_{ij} et l'angle θ_{ij} du gradient (modulo 2π) sont alors déterminés.
- un voisinage carré W de côté σ_2 est déplacé sur l'image par pas de Δ pixels. Pour chaque position (x, y) de ce voisinage on calcule l'orientation principale $\hat{\theta}_{xy}$ (modulo π) et sa confiance associée c_{xy} (comprise entre 0 et 1) :

$$\hat{\theta}_{xy} = \frac{1}{2} \arctan \left(\frac{\sum_{(i,j) \in W} \rho_{ij}^2 \sin(2\theta_{ij})}{\sum_{(i,j) \in W} \rho_{ij}^2 \cos(2\theta_{ij})} \right) \text{ et } c_{xy} = \frac{\sum_{(i,j) \in W} \rho_{ij} \cos(\hat{\theta}_{xy} - \theta_{ij})}{\sum_{(i,j) \in W} \rho_{ij}} \quad (\text{A.1})$$

Les paramètres σ_1 , σ_2 et Δ dépendent du type d'analyse envisagée. En particulier le paramètre Δ détermine si on va procéder à un lissage de taille σ_2 des orientations ($\Delta = 1$) ou si on va agrèger l'information d'orientation de manière à obtenir l'estimation de l'orientation à une échelle plus large ($\Delta = \sigma_2$). Il est également possible de combiner le lissage et l'agrégation des données si $1 < \Delta < \sigma_2$.

Vecteur Directionnel Moyen

Le calcul du Vecteur Directionnel Moyen (VDM) [Ger 97] permet d'estimer la tendance directionnelle moyenne d'un champ de vecteurs.

Tout comme l'algorithme de Rao, le calcul du VDM se base sur l'utilisation du vecteur d'angle double.

Soit $v_i, i = (1, \dots, N)$ l'ensemble des vecteurs du champ V dont on souhaite déterminer le VDM.

Chacun de ces vecteurs peut s'exprimer sous une forme polaire par $v_i \rightarrow z_i = \rho_i e^{i\theta_i}$

Le VDM s'exprime alors par :

$$VDM(V) = \left\| \frac{1}{N} \sum_{i=1}^N \frac{z_i^2}{\rho_i} \right\|^{\frac{1}{2}} \left(\frac{1}{N} \sum_{i=1}^N \frac{z_i^2}{\rho_i} \right)^{\frac{1}{2}} \quad (\text{A.2})$$

En pratique, le calcul du VDM se décompose en trois étapes :

- doubler l'argument des vecteurs
- effectuer la somme vectorielle des éléments du champ ainsi obtenu
- diviser l'argument du vecteur résultat par deux

Le champ de vecteurs V est défini par un voisinage carré W dont la taille correspond au changement d'échelle désiré.

Intérêt de la représentation de l'orientation

Nous constatons que ces deux méthodes s'appuient sur l'utilisation du vecteur d'angle double [Mar 72], qui correspond à une des représentations de l'orientation que nous avons présentées en (1.2.3).

Ces deux méthodes n'ont d'intérêt que dans le cas où les données de base sont les champs de vecteurs issus de l'estimation des gradients locaux. En effet, si ces données relatives à l'orientation sont traduites via une représentation de l'orientation respectant la condition d'équivariance, le calcul de la moyenne des orientations devient trivial.

Par exemple, Knutsson et al. [Knu 94] se fondent sur l'utilisation d'un champ de tenseurs. Le tenseur moyen s'exprime comme la moyenne des tenseurs du champ étudié :

$$T_M = \frac{1}{N} \sum_{i=1}^N T_i = \frac{1}{N} \sum_{i=1}^N v_i v_i^T \quad (\text{A.3})$$

Donias [Don 99] montre d'ailleurs, dans le cas où la pondération est uniforme, l'équivalence entre les méthodes de Rao, du Vecteur Directionnel Moyen ou encore de l'algorithme de Kass et Witkin [Kas 87]. Ces méthodes sont alors comparables à l'Analyse en Composantes Principales (ACP), aussi connue sous le nom de transformée de Karhunen-Loève [Loè 63] en imposant toutefois un centre de gravité à l'origine.

Annexe B : Masques de convolution des opérateurs GOP et VOP

Comme exemple d'opérateurs GOP et VOP, nous présentons le masque M_{G_x} de GOP5, qui ne présente aucun biais d'estimation pour des surfaces orientées non bruitées de fonction génératrice polynomiale d'ordre inférieur ou égal à 5, et les deux masques de VOP7, sans biais pour des surfaces de fonction génératrice polynomiale d'ordre inférieur ou égal à 6.

$$GOP5_x = \begin{bmatrix} -7 & 0 & 0 & 0 & 7 \\ -32 & 0 & 0 & 0 & 32 \\ -12 & 0 & 0 & 0 & 12 \\ -32 & 0 & 0 & 0 & 32 \\ -7 & 0 & 0 & 0 & 7 \end{bmatrix}$$

Masques de convolution du gradient GOP5

$$VOP7_1 = \begin{bmatrix} 0 & 0 & 0 & -116 & 0 & 0 & 0 \\ 0 & 0 & -426 & -1890 & -426 & 0 & 0 \\ 0 & 426 & 0 & 0 & 0 & 426 & 0 \\ 116 & 1890 & 0 & 0 & 0 & 1890 & 116 \\ 0 & 423 & 0 & 0 & 0 & 426 & 0 \\ 0 & 0 & -426 & -1890 & -426 & 0 & 0 \\ 0 & 0 & 0 & -116 & 0 & 0 & 0 \end{bmatrix}$$

$$VOP7_2 = \begin{bmatrix} 0 & -1254 & 0 & 1254 & 0 \\ -1254 & -564 & 0 & 564 & 1254 \\ 0 & 0 & 0 & 0 & 0 \\ 1254 & 564 & 0 & -564 & 1254 \\ 0 & 1254 & 0 & -1254 & 0 \end{bmatrix}$$

Masques de convolution du vallonnement VOP7

Annexe C : Fonction radiale des filtres wedge steerable

La fonction radiale choisie dans [Sim 96] est nulle au centre et sur la bordure extérieure du masque, et unitaire sur une couronne centrée :

$$w(r) = \begin{cases} 0 & \text{si } r < R_1 \\ \frac{1}{2} \left[1 - \cos \left(\frac{\pi(r - R_1)}{\delta_1} \right) \right] & \text{si } R_1 \leq r < R_1 + \delta_1 \\ 1 & \text{si } R_1 + \delta_1 \leq r < R_2 - \delta_2 \\ \frac{1}{2} \left[1 + \cos \left(\frac{\pi(r + \delta_2 - R_2)}{\delta_2} \right) \right] & \text{si } R_2 - \delta_2 \leq r < R_2 \\ 0 & \text{si } R_2 \leq r \end{cases}$$

Nombre de paires de filtres de base	3	5	9	18
Coefficients harmoniques optimaux	$a_1 = 0,2665$ $a_2 = -0,5063$ $a_3 = 0,5876$	$a_1 = 0,1242$ $a_2 = -0,258$ $a_3 = 0,3616$ $a_4 = -0,4298$ $a_5 = 0,4524$	$a_1 = -0,0471$ $a_2 = 0,1014$ $a_3 = -0,1513$ $a_4 = 0,1976$ $a_5 = -0,238$ $a_6 = 0,2720$ $a_7 = -0,298$ $a_8 = 0,3163$ $a_9 = -0,3254$	$a_1 = 0,0172$ $a_2 = -0,0374$ $a_3 = 0,0568$ $a_4 = -0,076$ $a_5 = 0,945$ $a_6 = -0,1124$ $a_7 = 0,1294$ $a_8 = -0,1455$ $a_9 = 0,1605$ $a_{10} = -0,1744$ $a_{11} = 0,187$ $a_{12} = -0,1982$ $a_{13} = 0,208$ $a_{14} = -0,2162$ $a_{15} = 0,2229$ $a_{16} = -0,2280$ $a_{17} = 0,2313$ $a_{18} = -0,233$

Coefficients harmoniques optimaux en fonction du nombre de filtres de base

Annexe D : Analyse de la réponse angulaire

Les filtres orientés présentés en partie 1.3.2 fournissent en chaque point (x, y) d'une image I une réponse angulaire $R(\theta)$. En général cette réponse angulaire est échantillonnée sur N_R points et s'exprime donc sous la forme $R(\theta_i)$, $i \in (1, \dots, N_R)$.

Afin de déterminer la ou les orientations en ce point il est nécessaire d'extraire les modes de cette réponse angulaire. Nous détaillons ici les méthodes utilisées à cet effet.

Détection de la présence d'orientation

Avant de se préoccuper d'analyser la réponse angulaire $R(\theta)$ d'un opérateur, il convient de déterminer si au moins une orientation est présente au point étudié.

Si la réponse est isotrope, aucune orientation n'est présente. Nous comparons donc la moyenne de $R(\theta)$ à sa valeur maximale. Si l'écart entre les deux est trop faible, nous déduisons qu'il n'y a aucune orientation au point étudié.

Recherche d'une seule orientation

Dans le cas où il n'existe qu'une seule orientation locale à estimer, cette orientation correspond au maximum de $R(\theta)$.

La recherche du maximum peut s'effectuer directement sur l'échantillonnage $R(\theta_i)$ de $R(\theta)$ et conduit à la détermination de l'angle échantillonné recherché.

L'estimation de l'orientation est alors limitée par le pas d'échantillonnage choisi (du point de vue de la donnée finale obtenue, cet échantillonnage correspond à une quantification de la mesure d'orientation).

Notons que cet échantillonnage de la réponse angulaire correspond à une quantification des orientations estimées sur l'image.

Il est cependant possible d'améliorer la précision angulaire de l'estimation. Chaque échantillon de $R(\theta_i)$ correspond à la réponse énergétique du filtre dans une direction donnée. Estimer la direction principale déterminée par la réponse angulaire $R(\theta_i)$ équivaut donc à estimer la direction principale d'un champ de vecteurs :

$$V = \{v_i = (R(\theta_i) \cdot \cos(\theta_i), R(\theta_i) \cdot \sin(\theta_i))\}.$$

Nous pouvons pour cela calculer le VDM, l'ACP ou encore le tenseur moyen de ce champ de vecteurs.

Recherche d'orientations multiples

Afin de déterminer des orientations multiples, il est nécessaire de déterminer les maxima de la réponse angulaire échantillonnée $R(\theta_i)$, $i \in (1, \dots, N_R)$. Nous ne nous intéressons pas à tous les maxima locaux mais uniquement à ceux qui correspondent aux modes recherchés dans la réponse angulaire.

Nous décrivons ici l'algorithme qui permet de déterminer ces maxima locaux significatifs.

Nous commençons par effectuer un changement d'abscisse de la réponse angulaire en prenant le minimum absolu comme nouvelle origine. Grâce à ce changement d'abscisse, la recherche des maxima peut désormais s'effectuer sans avoir à considérer la circularité de $R(\theta_i)$.

Après ce changement d'abscisse, nous notons $R(\theta_k)$ la nouvelle courbe à étudier.

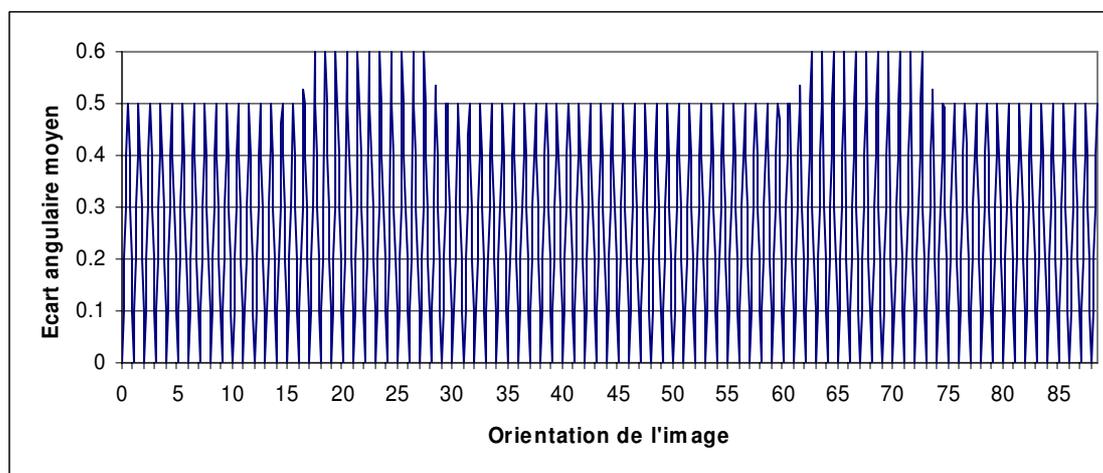
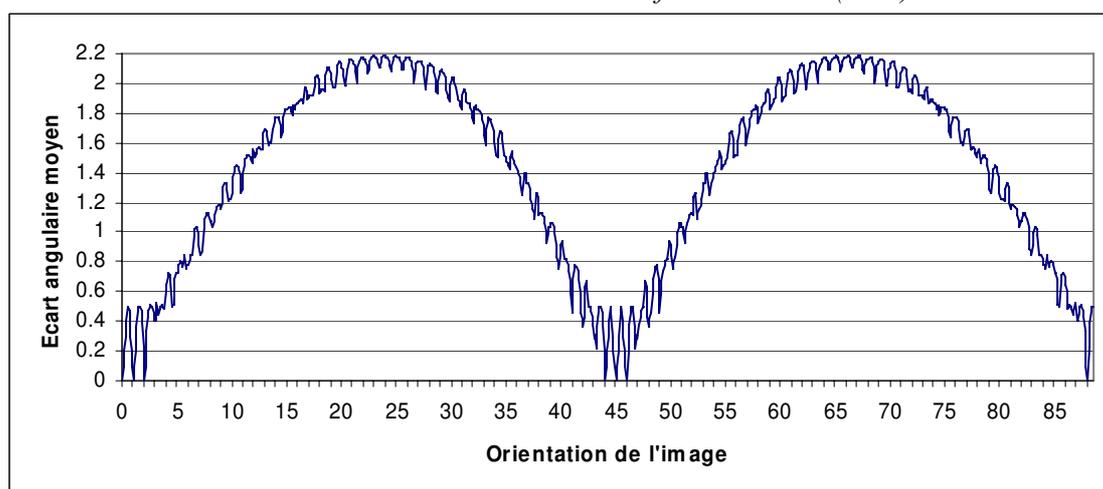
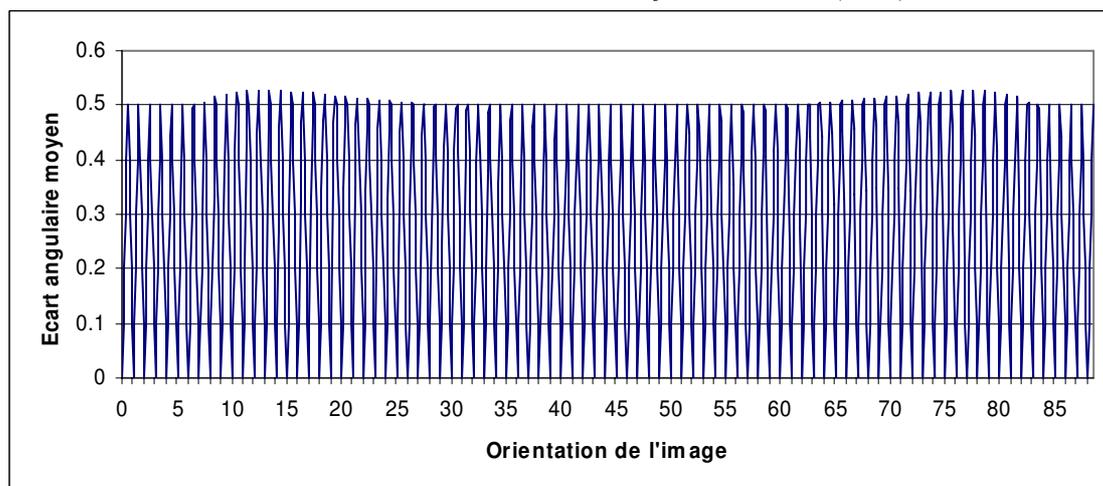
Nous déterminons maintenant l'ensemble des extrema locaux de $R(\theta_k)$. Nous fixons alors un seuil relatif, proportionnel à la différence entre le maximum absolu et le minimum absolu de $R(\theta_k)$, qui va nous permettre de déterminer quels seront les maxima significatifs.

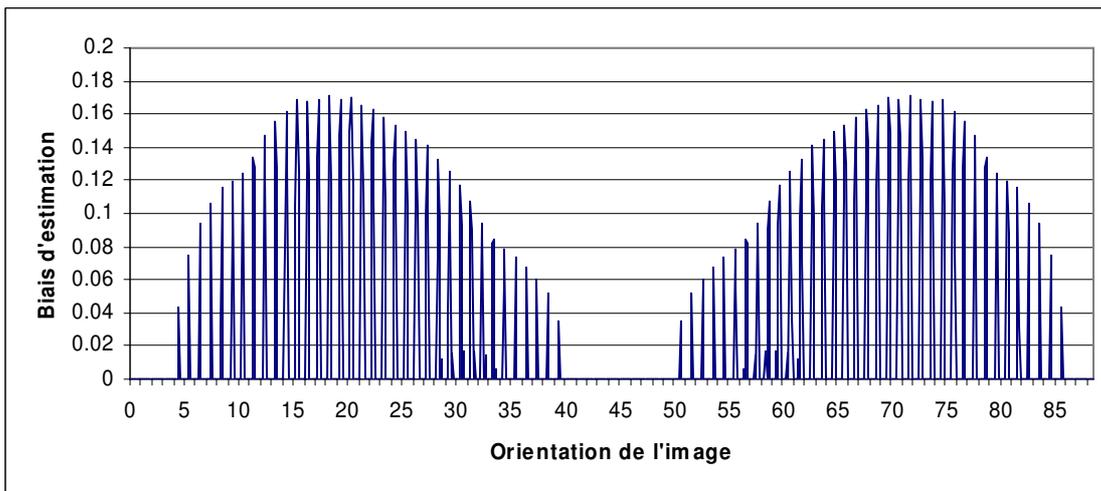
Nous calculons alors les écarts (en valeur absolue) entre chaque extrema local successif de $R(\theta_k)$. Nous déterminons le couple pour lequel cet écart est le plus faible.

Se présentent alors deux possibilités :

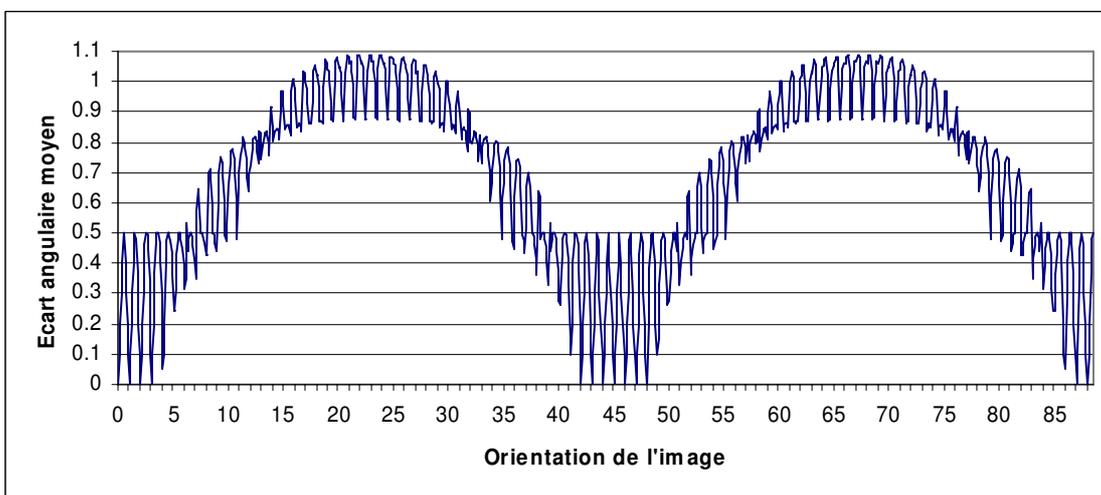
- si cet écart est inférieur au seuil fixé, alors nous éliminons les deux extrema correspondants et nous renouvelons l'opération avec les extrema restants.
- sinon, les seuls extrema restants sont significatifs (par rapport au seuil que nous avons fixé) et les maxima correspondent donc aux modes recherchés sur la réponse angulaire.

Il suffit pour terminer de déterminer les angles correspondant aux indices k de ces maxima.

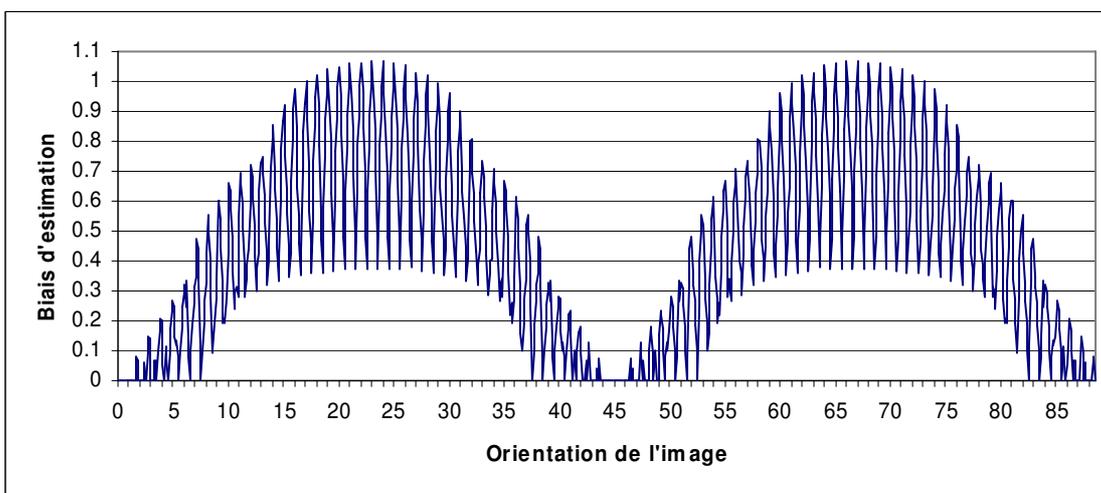
Annexe E : Erreur d'estimation en fonction de θ *Filtres steerable E2 : EAM en fonction de θ ($E=5$)**Filtres steerable E4 : EAM en fonction de θ ($E=5$)**Filtres steerable E2 : EAM en fonction de θ ($E=15$)*



Filtres steerable E2 : Biais d'estimation en fonction de θ ($E=15$)



Filtres steerable E4 : EAM en fonction de θ ($E=15$)



Filtres steerable E4 : Biais d'estimation en fonction de θ ($E=15$)

Annexe F : Variationnelle théorique

En supposant l'image I constante et égale à zéro, et bruitée par un bruit blanc gaussien de variance σ_B^2 , alors la valeur des niveaux de gris sur la ligne peut être exprimée par une variable aléatoire X_i .

La loi de probabilité de cette variable aléatoire est :

$$P_{X_i}(x) = \frac{I}{\sqrt{2\pi}\sigma_B} \exp\left(-\frac{x^2}{2\sigma_B^2}\right) \quad (\text{F.1})$$

Les valeurs de niveau de gris en chaque point de la ligne étant décorréliées, la loi de probabilité de la différence entre deux niveaux de gris successifs a une variance deux fois plus grande :

$$P_{X_i - X_{i+1}}(x) = \frac{I}{2\sqrt{\pi}\sigma_B} \exp\left(-\frac{x^2}{4\sigma_B^2}\right), x \in \mathfrak{R} \quad (\text{F.2})$$

En prenant la valeur absolue de la différence, il vient :

$$P_{|X_i - X_{i+1}|}(x) = \begin{cases} \frac{I}{\sqrt{\pi}\sigma_B} \exp\left(-\frac{x^2}{4\sigma_B^2}\right) & \text{si } x \in \mathfrak{R}^+ \\ 0 & \text{sinon} \end{cases} \quad (\text{F.3})$$

Nous calculons maintenant l'espérance de cette différence en valeur absolue :

$$E(|X_i - X_{i+1}|) = \int_{x=0}^{+\infty} \frac{x}{\sqrt{\pi}\sigma_B} \exp\left(-\frac{x^2}{4\sigma_B^2}\right) dx \quad (\text{F.4})$$

En posant $y = x^2$, il vient :

$$E(|X_i - X_{i+1}|) = \int_{y=0}^{+\infty} \frac{1}{\sqrt{\pi}\sigma_B} \exp\left(-\frac{y}{4\sigma_B^2}\right) dy \quad (\text{F.5})$$

Soit :

$$E(|X_i - X_{i+1}|) = \frac{2\sigma_B}{\sqrt{\pi}} \quad (\text{F.5})$$

Annexe G : Calcul récursif de l'attribut

Le calcul récursif de l'attribut Δ (variance ou variationnelle) s'effectue sur l'image ayant subi une rotation d'angle $-\theta_k$. Nous prenons ici l'exemple d'un réseau de L lignes avec p points par ligne.

Le calcul de l'attribut Δ est séparable en x-y. Il se décompose donc en deux étapes :

- calcul récursif de la valeur de l'attribut pour chacune des lignes de l'image,
- somme récursive des attributs de chaque ligne pour déterminer la valeur de l'attribut sur l'ensemble du réseau.

Pour la première étape, il convient tout d'abord d'initialiser le calcul en début de ligne. Ensuite nous calculons la valeur recherchée $\Delta_j(x+1)$ au point d'abscisse $x+1$ à partir de la valeur $\Delta_j(x)$ au point d'abscisse x .

Pour le calcul de la variance cela revient à mettre à jour les sommes $\sum_{i=1}^p v_i$ et $\sum_{i=1}^p (v_i)^2$ qui interviennent dans le calcul de la variance (relation 2.6).

Pour la variationnelle, il s'agit de mettre à jour la somme des écarts successifs

$$\sum_{i=1}^{p-1} |v_{i+1,j,\theta} - v_{i,j,\theta}|$$

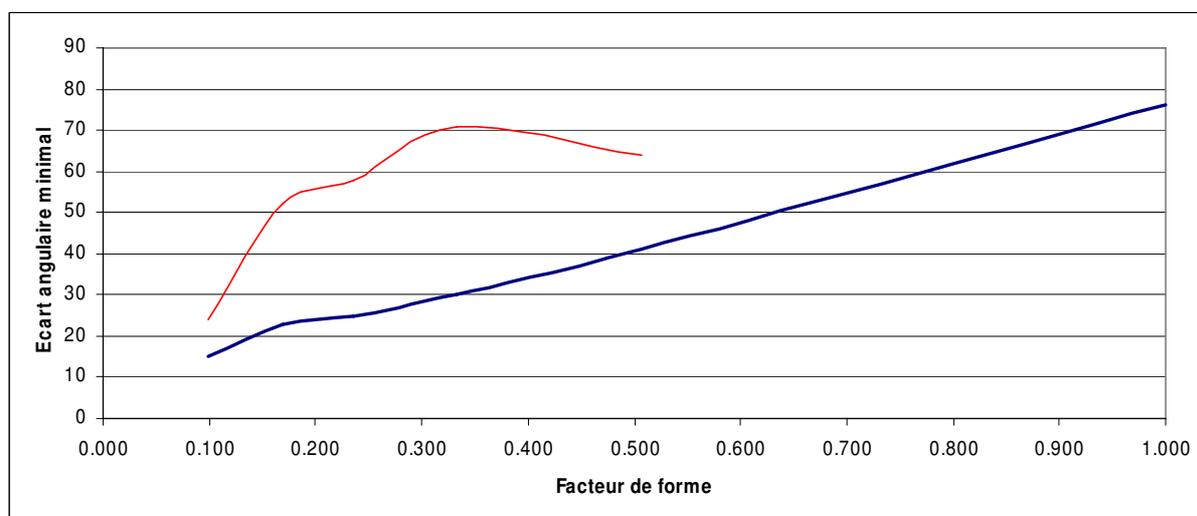
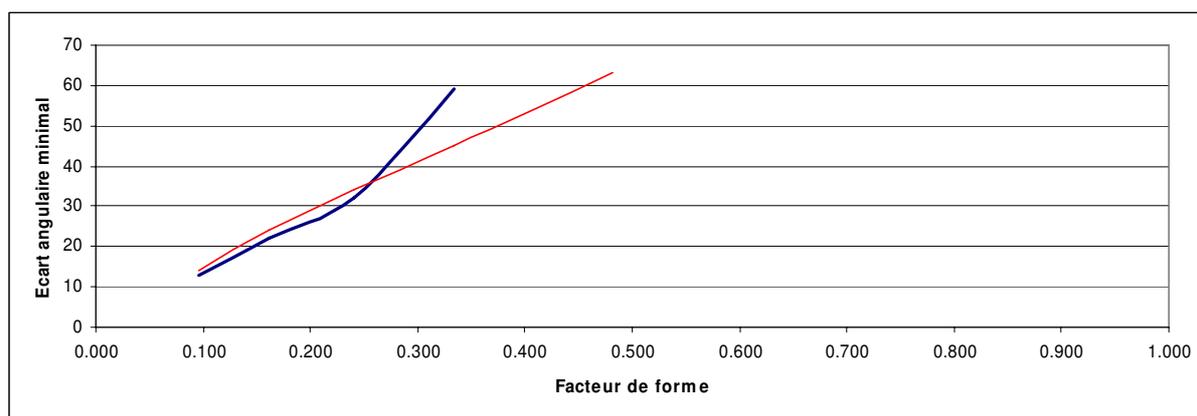
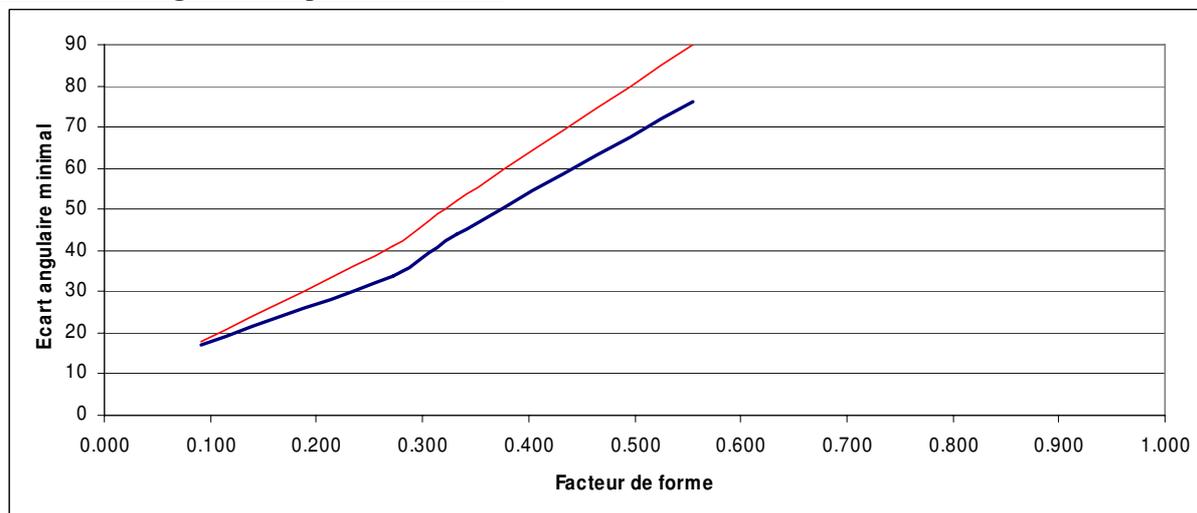
La mise à jour consiste simplement à soustraire à chaque somme leur première valeur et à leur ajouter la valeur suivante sur la ligne.

Une fois le calcul de l'attribut Δ_j effectué pour chacune des lignes de l'image, l'attribut Δ s'obtient par sommation sur L lignes des valeurs Δ_j .

De la même manière que pour le calcul de l'attribut Δ_j pour chaque ligne, cette somme est initialisée sur un bord de l'image puis évaluée de manière récursive, avec une simple mise à jour.

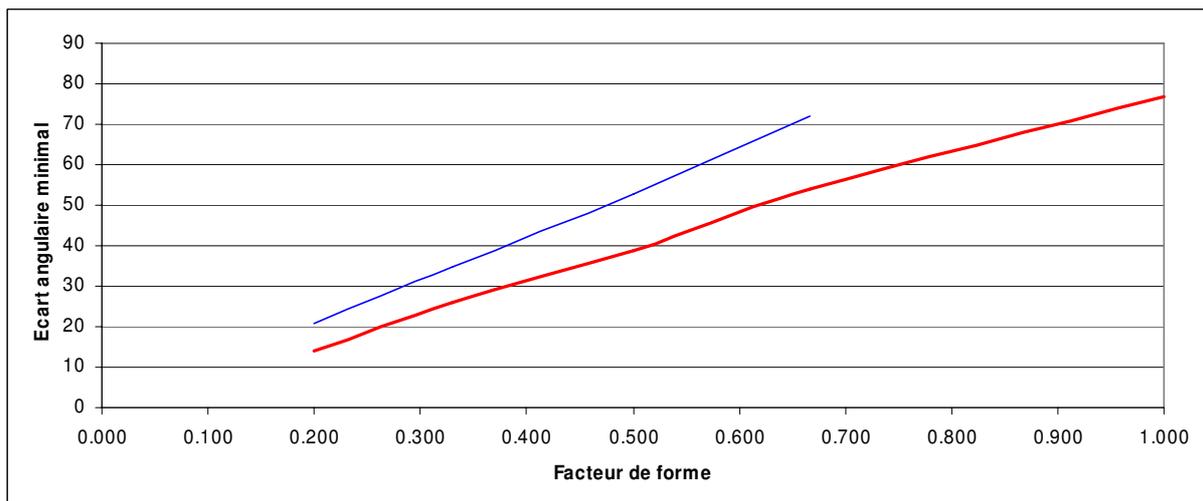
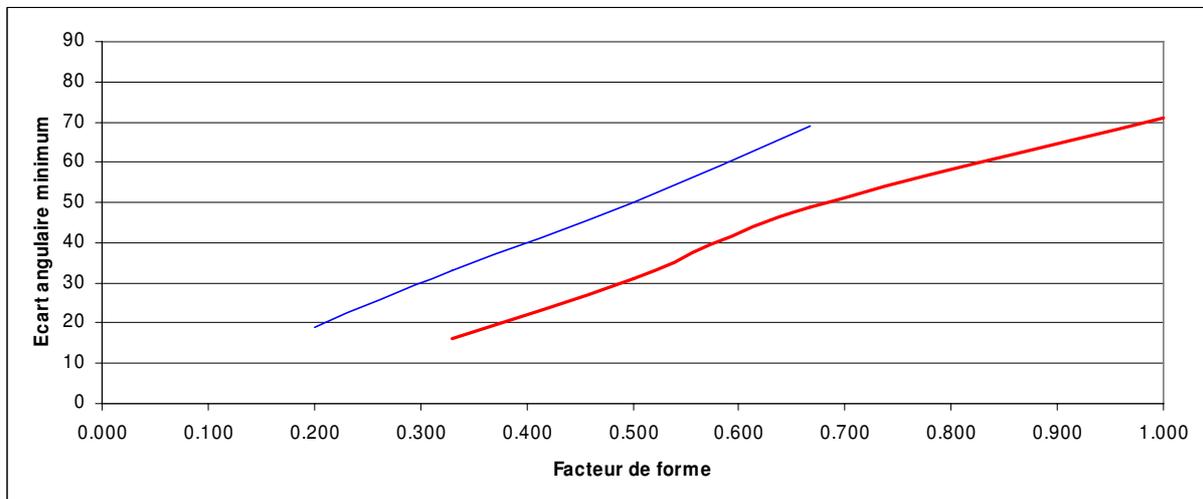
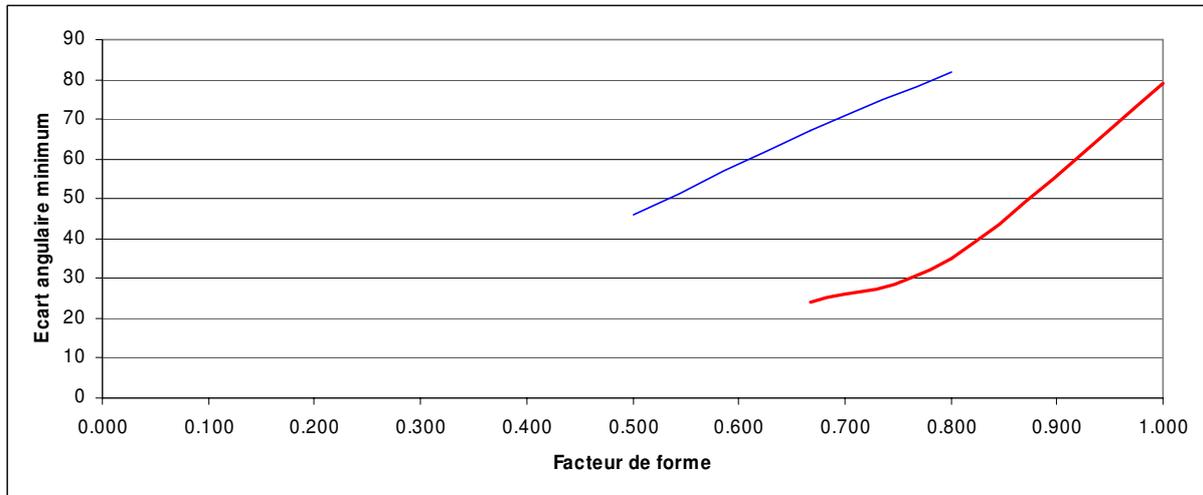
Annexe H : Sélectivité angulaire et réponse angulaire des opérateurs

Sélectivité angulaire : opérateur IRON

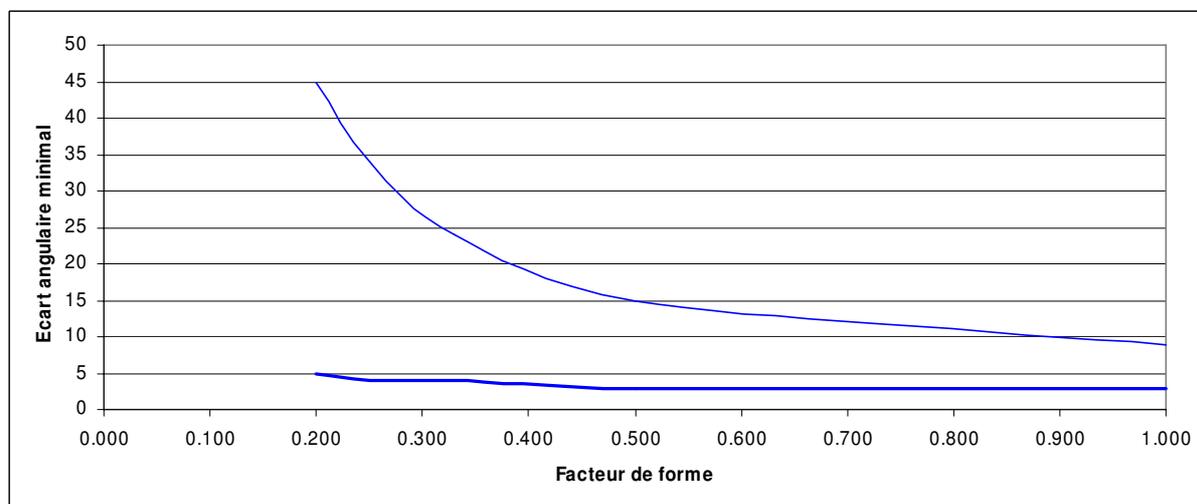


*IRON : Sélectivité angulaire $\Delta\theta_{50\%}$ en fonction du facteur de forme F
(échelles $E=5$, $E=15$ et $E=45$ – Variationnelle : trait fin, Variance : trait épais)*

Sélectivité angulaire : filtres Steerable



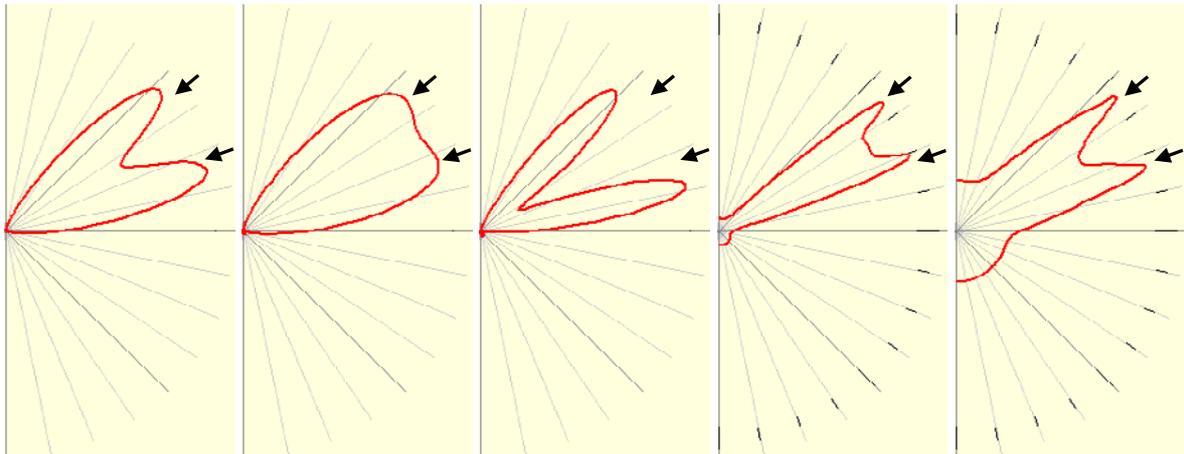
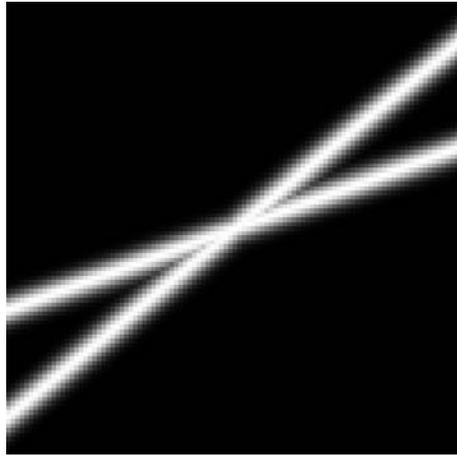
Filtres steerable : Sélectivité angulaire $\Delta\theta_{50\%}$ en fonction du facteur de forme F (échelles $E=5$, $E=15$ et $E=45$ – Filtre E2 : trait fin, Filtre E4 : trait épais)

Sélectivité angulaire : filtres de Gabor

*Filtres de Gabor : IRON : Sélectivité angulaire $\Delta\theta_{50\%}$ en fonction du facteur de forme F
Echelles $E=15$ (trait fin) et $E=45$ (trait épais)*

Allure des réponses angulaires des opérateurs

Nous présentons les réponses angulaires de différents opérateurs appliqués au point central de l'image, obtenues pour une échelle d'analyse $E=15$ et pour un facteur de forme $F=3$.

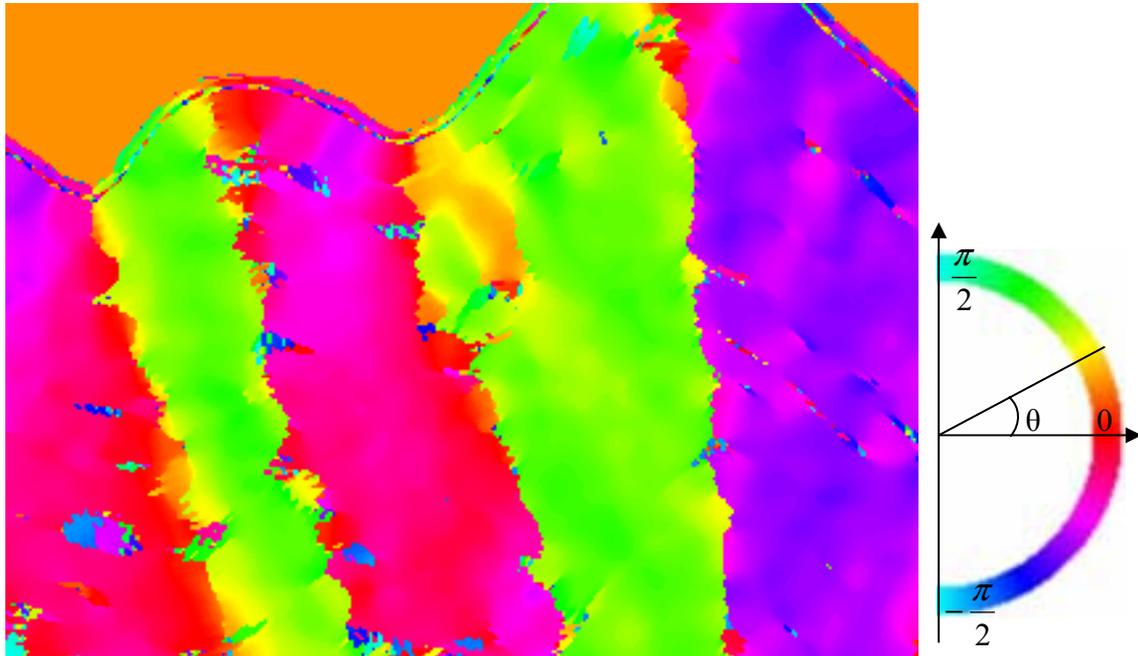


*Réponses angulaires des opérateurs ($E=15$, $F=3$), de gauche à droite :
Filtres de Gabor, filtres Steerable E2, filtres Steerable E4, IRON Variance et IRON
Variationnelle*

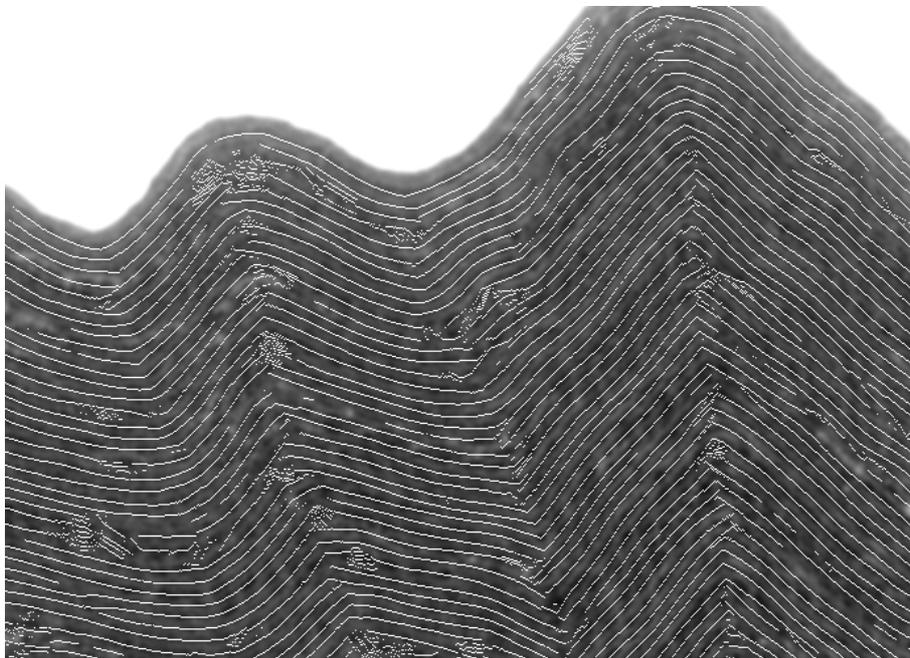
Les réponses angulaires présentées sont obtenues au point central de l'image, où deux orientations sont présentes : 20° et 40° . Ces orientations sont signalées par une flèche sur chacun des tracés des réponses angulaires.

Nous pouvons observer que les filtres de Gabor et les filtres steerable E4 distinguent bien les deux orientations présentes, mais avec une erreur assez importante. Sur la réponse des filtres steerable E2, les maxima correspondant aux orientations recherchées sont beaucoup moins marqués mais l'estimation des orientations est moins biaisée.

Enfin l'opérateur IRON détecte bien les deux orientations, et commet peu d'erreur sur leur estimation.

Annexe I : Utilisation des filtres de Gabor pour le suivi de strates

Carte d'orientation estimée par les filtres de Gabor ($E=30$, $T_0=9$)



Strates détectées grâce à la carte d'orientation obtenue par les filtres de Gabor

Bibliographie

[Ade 85] E.H. Adelson, J.R. Bergen – Spatiotemporal energy models for the perception of motion, *Journal of the Optical Society of America*, February 1985, Vol 2 n°2, pp. 284-299.

[And 91] M.T. Andersson, H. Knutsson – Orientation Estimation in Ambiguous Neighbourhoods, *Proceedings of Scandinavian Conference on Image Analysis*, Ålborg, Denmark, August 1991.

[Abr 96] E. Abreu, M. Lightstone, S.K. Mitra, K. Arakawa – A New Efficient Approach for the Removal of Impulse noise from Highly Corrupted Images, *IEEE Transactions on Image Processing*, June 1996, Vol 5, n°6, pp. 1012-1025.

[Ben 03] O. Ben-Shahar, S.W. Zucker – The Perceptual Organization of Texture Flow : A Contextual Inference Approach, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, April 1994, Vol 25, n°4, pp. 401-417.

[Big 94] J. Bigün, J. Hans du Buf – N-folded symmetries by complex moments in Gabor space and their application to unsupervised texture segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, January 1994, Vol 16, n°1, pp. 80-87.

[Bob 03] W. Bobillet, J.P. Da Costa, C. Germain, O. Laviolle, G. Grenier, Row detection in high resolution remote sensing images of vine fields, *Proceedings of European Conference on Precision Agriculture*, Wageningen Academic Publishers, Netherlands, 2003.

[Bül 01] T. Bülow, G. Sommer – Hypercomplex Signals - A Novel Extension of the Analytic Signal to the Multidimensional Case, *IEEE Transactions on Signal Processing*, November 2001, Vol 49, n°11, pp. 2844-2852.

[Can 83] J.F. Canny – *Finding Edges and Lines in Images*, Phd Thesis, Massachusetts Institute of Technology, June 1983.

[Che 98] J. Chen, Y. Sato, S. Tamura – Orientation Space Filtering for Multiple Line Segmentation, *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, California, 1998.

[Che 02] D. Chetverikov, A. Hanbury – Finding defects in texture using regularity and local orientation, *Pattern Recognition*, October 2002, Vol 35, pp. 2165-2180.

[Coc 95] J.P. Cocquerez, S. Phillipp – *Analyse d'images : filtrage et segmentation*, Masson, 1995.

[DaC 01] J.P. Da Costa, F. Le Pouliquen, C. Germain, P. Baylou – New Operators for Optimized Orientation Estimation, *Proceedings of IEEE International Conference on Image Processing*, Thessaloniki, Greece, October 2001.

[DaC 04] J.P. Da Costa, C. Germain, O. Laviolle, G. Grenier – Segmentation of high resolution remote sensing images : application to the automatic delineation of vine fields. *Proceedings of Agricultural Engineering*, 2004, pp. 324-325.

- [DaC 05] J.P. Da Costa, F. Michelet, C. Germain, O. Laviaille, G. Grenier – Delineation of Vine Fields by Segmentation of High Resolution Remote Sensed Images, *soumis à Precision Agriculture*
- [Der 90] R. Deriche – Fast Algorithms for Low-Level Vision, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, January 1990, Vol 12, n°1, pp. 78-81.
- [DoC 76] M.P. Do Carmo – *Differential Geometry of Curves and Surfaces*, Prentice Hall, 1976.
- [Don 99] M. Donias – *Caractérisation de champs d'orientation par Analyse en Composantes Principales et estimation de la courbure, Application aux images sismiques*, PhD Thesis, Université Bordeaux I, France, January 1999.
- [Fre 91] W.T. Freeman, E.H. Adelson – The design and use of steerable filters, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, September 1991, Vol 13, n°9, pp. 891-906.
- [Gag 83] A.P. Gagalowicz – *Vers un modèle de texture*, Thèse d'état, Université Pierre et Marie Curie, France, 1983.
- [Ger 97] C. Germain – *Contribution à la caractérisation multi-échelle de l'anisotropie des images texturées*, PhD Thesis, Université Bordeaux I, France, January 2003.
- [Ger 03] C. Germain, J.P. Da Costa, O. Laviaille, P. Baylou – Multiscale estimation of vector field anisotropy. Application to texture characterization, *Signal Processing*, July 2003, Vol 83, pp. 1487-1503.
- [Gra 78] G.H. Granlund – In search of a general picture processing operator, *Computer Graphics and Image Processing*, 1978, Vol 8, pp. 155-173.
- [Gra 95] G.H. Granlund, H. Knutsson – *Signal Processing for Computer Vision*, Kluwer, 1995.
- [Gue 02] J.P. Guédon – *L'histoire de la transformée Mojette*, Mémoire d'habilitation à diriger des recherches, Université de Nantes, 2002
- [Ive 95] L.A. Iverson, S.W. Zucker – Logical/Linear Operators for Images Curves, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, October 1995, Vol 17, n°10, pp. 982-996.
- [Jac 04] M. Jacob, M. Unser – Design of steerable filters for feature detection using Canny like criteria, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, August 2004, Vol 26, n°8, pp. 1007-1019.
- [Jai 89] A.K. Jain – *Fundamentals of Digital Image Processing*, Prentice-Hall, 1989.
- [Kas 87] M. Kass, A. Witkin – Analysing Oriented Patterns, *Computer Vision Graphics and Image Processing*, 1987, vol 37, pp. 362-385.
- [Key 81] R.G. Keys – Cubic convolution interpolation for digital image processing, *IEEE Transactions on Acoustic, Speech, and Signal Processing*, 1981, Vol ASSP 29, pp 1153-1160.

- [Knu 89] H. Knutsson – Representing Local Structure Using Tensors, *Proceedings of Scandinavian Conference on Image Analysis*, Oulu, Finland ; June, 1989.
- [Knu 94] H. Knutsson, M. Andersson – Robust N-Dimensional Orientation Estimation using Quadrature Filters and Tensor Whitening, *Proceedings of International Conference on Acoustics, Speech, and Signal Processing*, Adelaide, Australia, April, 1994.
- [Kri 96] G. Krieger, C. Zetsche – Nonlinear Image Operators for the Evaluation of Local Intrinsic Dimensionality, *IEEE Transaction on Image Processing*, June 1999, Vol 5, n°6, pp.1026-1042.
- [Leh 99] T.M. Lehmann, C. Gönner, K. Spitzer – Survey : Interpolation Methods in Medical Image Processing, *IEEE Transactions on Medical Imaging*, November 1999, Vol 18, n°11, pp. 1049-1075
- [LeP 01] F. Le Pouliquen, C. Germain, P. Baylou – Line Orientation Operator, *Proceedings of IEEE International Conference on Image Processing*, Thessaloniki, Greece, October 2001.
- [LeP 03] F. Le Pouliquen – *Opérateurs discrets pour l'estimation adaptative et optimale de l'orientation, Application à l'imagerie sismique*, PhD Thesis, Université Bordeaux I, France, January 2003.
- [Loè 63] M. Loève – *Probability Theory*, D. Van Nostrand Company, 1963.
- [Mar 72] K.V. Mardia – *Statistics of directional data*, Academic Press, 1972.
- [Mic 03] F. Michelet, C. Germain, P. Baylou – Estimation d'orientations multiples : utilisation du Réseau Orienté de Lignes, *Proceeding of GRETSI'03*, Paris, France, September 2003.
- [Mic 04] F. Michelet, C. Germain, P. Baylou, J.P. Da Costa – Local Multiple Orientation Estimation : Isotropic and Recursive Oriented Network, *Proceedings of International Conference on Pattern Recognition*, Cambridge, United Kingdom, August 2004.
- [Mic 05] F. Michelet, C. Germain, P. Baylou – Estimation robuste de l'orientation locale par l'opérateur IRON, *Proceedings of GRETSI'05*, Louvain-la-Neuve, Belgium, September 2005.
- [Nor 93] K. Nordberg, H. Knutsson, G. Granlund – On the Equivariance of the Orientation and the Tensor Field Representation, *Proceedings of Scandinavian Conference on Image Analysis*, May 1993.
- [Owe 96] C. Owen, F. Makedon – High Quality Alias Free Image Rotation, *Proceedings of Asilomar Conference on Signal, Systems, and Computers*, Pacific Grove, California, November 1996.
- [Per 92] P. Perona – Steerable-Scalable Kernels for Edge Detection and Junction Analysis, *Proceedings of European Conference on Computer Vision*, 1992.
- [Per 95] P. Perona – Deformable kernels for early vision, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, May 1995, Vol 17, n°5, pp. 488-499.

- [Rab 05] G. Rabatel, C. Debain, M. Deshayes – Vine parcel detection in aerial images combining textural and structural approaches, *Proceedings of ECPA 2005*, pp. 923-932.
- [Rao 90] A.R. Rao – *A Taxonomy for Texture Description and Identification*, Springer, 1990.
- [Rou 74] J.W. Rouse, R.H. Haas, D.W. Deering, J.A. Schell, J.C. Harlan – Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation, *NASA/GSFC Type III Final Report*, 1974, Greenbelt, MD, p371.
- [Sim 96] E.P. Simoncelli and H. Farid – Steerable Wedge Filters for Local Orientation Analysis, *IEEE Transactions on Image Processing*, September 1996, Vol 5, n°9, pp. 1377-1382.
- [Som 98] G. Sommer, M. Michaelis, R. Herpers – The SVD Approach for Steerable Filter Design, *Proceeding of the International Symposium on Circuits and Systems*, Vol 5, pp. 349-353, 1998.
- [Thé 00] P. Thévenaz, T. Blu, M. Unser – Image Interpolation and Resampling, *Handbook of Medical Imaging, Processing and Analysis I.N. Bankman Ed.*, Academic Press, San Diego, USA, pp. 393-420, 2000.
- [Uns 84] M. Unser – *Description statistique de la texture, Application à l'inspection automatique*, Thèse de docteur es Sciences, EPFL, Lausanne, 1984.
- [Uns 91] M. Unser – Fast B-Spline Transforms for Continuous Image Representation and Interpolation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, March 1991, Vol 13, n°3, pp. 277-285.
- [Uns 95] M. Unser, P. Thévenaz, L. Yaroslavsky – Convolution-Based Interpolation for Fast, High-Quality Rotation of Images, *IEEE Transactions on Image Processing*, October 1995, Vol 4, n°10, pp. 1371-1381.
- [Uns 99] M. Unser – Splines: A Perfect Fit for Signal and Image Processing, *IEEE Signal Processing Magazine*, November 1999, Vol 16, n°6, pp. 22-38.
- [Uns 02] M. Unser – Splines : A Perfect Fit for Medical Imaging, *Proceedings of Symposium on Medical Imaging*, San Diego, USA, February 2002.
- [You 00] .T. Young, L.J. van Vliet, M. van Ginkel – Recursive Gabor filtering, *Proceedings of IEEE International Conference on Pattern Recognition*, Barcelone, Spain, September 2000.
- [Yu 00] W. Yu, K. Daniilidis, G. Sommer – Multiple Motion Analysis Using 3D Orientation Steerable Filters, *Technical Report 2008*, Christian-Albrechts-Universität, Kiel, December 2000.
- [Yu 01] W. Yu, K. Daniilidis, G. Sommer – Approximate Orientation Steerability Based on Angular Gaussians, *IEEE Transactions on Image Processing*, February 2001, Vol 10, n°2, pp. 193-205.
- [Yu 03] W. Yu, G. Sommer, K. Daniilidis – Three dimensional Orientation signatures with conic kernel filtering for multiple motion analysis, *Image and Vision Computing* , 2003, Vol 21, n°5, pp. 447-458.

Publications de l'auteur

Publications référencées dans la bibliographie

[Mic 03] F. Michelet, C. Germain, P. Baylou – Estimation d'orientations multiples : utilisation du Réseau Orienté de Lignes, *Proceeding of GRETSI'03*, Paris, France, September 2003.

[Mic 04] F. Michelet, C. Germain, P. Baylou, J.P. Da Costa – Local Multiple Orientation Estimation : Isotropic and Recursive Oriented Network, *Proceedings of International Conference on Pattern Recognition*, Cambridge, United Kingdom, August 2004.

[Mic 05] F. Michelet, C. Germain, P. Baylou – Estimation robuste de l'orientation locale par l'opérateur IRON, *Proceedings of GRETSI'05*, Louvain-la-Neuve, Belgium, September 2005.

[DaC 05] J.P. Da Costa, F. Michelet, C. Germain, O. Laviaille, G. Grenier – Delineation of Vine Fields by Segmentation of High Resolution Remote Sensed Images, soumis à Precision Agriculture

Publications non référencées dans la bibliographie

[Mic 06] F. Michelet, J.P. Da Costa, O. Laviaille, Y. Berthoumieu, P. Baylou, C. Germain – Estimating Local Multiple Orientations, soumis à Signal Processing

Résumé - Ce mémoire traite de l'estimation des orientations locales multiples présentes dans les images directionnelles, c'est-à-dire des images montrant un agencement spatial anisotrope. Nous proposons une nouvelle définition des orientations locales fondée sur des considérations perceptuelles. Grâce à cette définition et à des modèles d'images orientées, nous proposons un opérateur d'estimation des orientations locales. Cet opérateur prend la forme d'un réseau de lignes orientées, le long desquelles nous mesurons l'adéquation de l'image avec un modèle de voisinage orienté. Une implantation rapide et récursive est proposée. Nous obtenons ainsi l'opérateur Isotropic and Recursive Oriented Network (IRON).

Avec un support de calcul de dimensions réduites, l'opérateur IRON est capable d'estimer les orientations locales uniques sans biais et avec une bonne robustesse au bruit. Il détecte les orientations locales multiples avec une meilleure sélectivité angulaire que les méthodes classiques d'estimation des orientations multiples.

Le choix de la géométrie du réseau et le choix de l'attribut mesurant l'écart au modèle permettent d'adapter l'opérateur IRON à des situations d'estimation variées, telles que la présence de bruit impulsionnel ou d'une modulation d'amplitude. Nous proposons également une version adaptative en échelle de notre opérateur.

Les performances de l'opérateur IRON sont confirmées pour des cas concrets d'application, en particulier la caractérisation de matériaux et la segmentation de parcelles viticoles.

Mots clés : analyse d'images, orientation, orientations locales multiples, filtres orientés, estimation d'orientations.

Abstract - This thesis deals with multiple local orientation estimation in directional images. Those images present specific spatial arrangements.

We propose here a new definition of local orientations, based on perceptual factors. Thanks to that definition and to oriented image models, we propose a new operator for multiple local orientation estimation. This operator consists in an oriented network, along which we evaluate the conformity of the image with an oriented neighbourhood model. The fast and recursive implementation of this method is called the Isotropic and Recursive Oriented Network (IRON).

On a small computing support, IRON is able to estimate single local orientations without any bias, and provides us with good noise robustness. It can achieve multiple orientation estimation with better angular selectivity than classical methods.

The geometry of the network and the choice of the attribute evaluating the distance to the model allow us to operate IRON in various situations, such as additive impulse noise or amplitude modulation. We also propose a scale adaptive version of our operator.

Application results on material characterisation and vineyard segmentation assess the performances of the IRON operator.

Keywords - image analysis, orientation, multiple local orientations, steerable filters, orientation estimation.