

ÉCOLE DOCTORALE MATHÉMATIQUES,
INFORMATIQUE, PHYSIQUE THÉORIQUE ET
INGÉNIERIE DES SYSTÈMES

Laboratoire Imagerie Multimodale Multiéchelle et
Modélisation du Tissu Osseux et articulaire (I3MTO)

THÈSE présentée par :

Fouad BOUDJENOUIA

Soutenue le : 26 octobre 2017

pour obtenir le grade de : Docteur de l'université d'Orléans

Discipline / Spécialité : Traitement des images et du signal

Restauration d'images avec critères orientés qualité

THÈSE dirigée par :

Karim ABED-MERAIM
Rachid JENNANE

Professeur, Université d'Orléans, Directeur de thèse
Professeur, Université d'Orléans, CoDirecteur de thèse

RAPPORTEURS :

Ali MOHAMMAD-DJAFARI
Alain TRÉMEAU

Professeur, DR.CNRS, Université de Paris Sud
Professeur, LaHC, Université Jean-Monnet

JURY :

Jean-Louis ROUET
Alain TRÉMEAU
Anissa MOKRAOUI
Abd-krim SEGHOUANE
Karim ABED-MERAIM
Rachid JENNANE
Aladine CHETOUANI

Professeur, Université d'Orléans, Président du jury
Professeur, LaHC, Université Jean-Monnet, Rapporteur
Professeur, L2TI, Université Paris 13, Examineur
ARC-Fellow, Université de Melbourne, Examineur
Professeur, Université d'Orléans, Directeur de thèse
Professeur, Université d'Orléans, Co-Directeur de thèse
Maître de Conférences, Université d'Orléans, Encadrant

Remerciements

Je tiens tout d'abord à exprimer ma plus sincère gratitude à mes directeurs de thèse, Professeur Karim Abed-Meraim et Professeur Rachid Jennane et à mon encadrant Aladine Chetouani, pour m'avoir donné l'occasion de travailler avec eux, pour leur aide, leur soutien, leur compréhension, leur confiance en moi ainsi que leur disponibilité, une supervision précieuse et des conseils utiles pour mes recherches, sans lesquelles une grande partie de ce travail n'aurait pas été possible.

J'exprime ma profonde reconnaissance à Monsieur le Professeur Ali Mohammad-Djafari et à Monsieur le Professeur Alain Trémeau pour m'avoir fait l'honneur de rapporter sur mon travail ainsi que pour leurs remarques pertinentes. Je remercie également Monsieur le Professeur Jean-Louis Rouet, Madame le Professeur Anissa Mokraoui et Monsieur Abdkrim Seghouane d'avoir bien voulu évaluer cette thèse en participant au jury.

Je tiens à exprimer toute ma gratitude à Monsieur le docteur Eric Lespessailles et à Monsieur le professeur Hechmi Toumi pour leur aide et leur conseils.

Je tiens à remercier mes amis et collègues du laboratoire I3MTO qui m'ont soutenu pendant les trois années de mes études, en particulier M. Hafri, M. Cherief, G. Larguech, A. Brahim, R. Rabiâ, A. Allan, N. Souli, S. Brahim et aussi ceux du laboratoire PRISME : N. Lassami, F. Ahmed Sid, A. Bouelam, M. Nait-Meziane, A. Abbadi, A. Boudjellal.

Je voudrais exprimer ma profonde gratitude à mes parents pour leur amour et leurs encouragements constants. Je tiens sincèrement à remercier mon épouse S. Bentaleb qui a su m'épauler et me donner le courage aux moments difficiles et pour tout ce qu'elle a sacrifié pour mon succès, ainsi mes enfants LINA, LOAY et LOUJAINE pour leur amour et leur présence dans ma vie. C'est à eux que je dédie cette thèse sans oublier mes frères et sœurs.

Abréviations

ADMM	Alternating Direction Method of Multipliers	AMUSE	Algorithm for Multiple Unknown Signals Extraction
BSI	Blind System Identification	BSS	Blind Source Separation
CLS	Constrained Least Squares	CMSE	Constrained Mean Square Error
CR	Cross Relations	DEXA	Dual Energy X-ray Absorption
EM	Expectation Maximization	FA	Factor Analysis
FastICA	Fast Independent Component Analysis	FR-IQA	Full Reference Image Quality Assessment
GCV	Generalized Cross Validation	GD	Gradient Descente
HOS	Higher Order Statistics	HVS	Human Visual System
ICA	Independent Component Analysis	IQA	Image Quality Assessment
IQM	Image Quality Metrics	InfoMax	Information Maximisation
IR	Image Restoration	ISBS	Iterative Sparse Blind Separation
JADE	Joint Approximation Diagonalization of Eigen-matrices	JD	Joint Diagonalization
MAE	Mean Absolute Error	MC	Multi-Channel
ML	Maximum Likelihood	MNS	Minimum Noise Subspace method
MRE	Mutually Referenced Equalizers	MRF	Markov Random Field
MSE	Mean Square Error	NMSE	Normalized Mean Square Error
NR-IQA	No Reference Image Quality Assessment	PCA	Principal Component Analysis
PSF	Point Spread Function	PSNR	Peak Signal to Noise Ratio
ROF	Rudin Osher and Fatemi model	RR-IQA	Reduced Reference Image Quality Assessment
R-SCR	Robust-Symmetric Cross Relations	SCR	Symmetric Cross Relations
SD	Sphere Decoding	SIMO	Single Input Multiple Output
SISO	Single Input Single Output	SNR	Signal to Noise Ratio
SOBI	Second Order Blind Identification	SOS	Second Order Statistics
SS	Sub-Space method	SSIM	Structural SIMilarity index
SVD	Singular Value Decomposition	TV	Total Variation
VIF	Visual Information Fidelity	WASOBI	Weights-Adjusted Second Order Blind Identification

Table des matières

Remerciements	i
Abréviations	ii
Introduction générale	1
1 État de l'Art	6
1.1 Introduction	7
1.1.1 Formulation mathématique du problème	7
1.2 Identification aveugle des systèmes	8
1.2.1 Diversité des canaux et conditions d'identifiabilité	9
1.2.2 Les méthodes sous-espaces	10
1.2.3 La méthode du maximum de vraisemblance	12
1.3 Restauration multi-canal d'images	13
1.3.1 Classification des méthodes de la restauration d'images, selon l'étape d'identification	14
1.3.2 Méthodes non-aveugle de restauration d'images	15
1.3.3 Méthodes de restauration aveugle d'images	16
1.3.4 Autres méthodes et approches de restauration d'images	19
1.4 Évaluation de la qualité des images	19
1.4.1 Classification des méthodes IQA	20
1.4.2 Métriques d'évaluation perceptuelle de la qualité d'image	23
1.5 Séparation aveugle de sources images	26
1.5.1 Techniques classiques de décomposition	26
1.5.2 Méthodes statistiques du second ordre pour la BSS	28
1.5.3 Méthodes des statistiques d'ordre supérieur pour la BSS	30
1.6 Conclusion	32
2 Identification aveugle des systèmes	33
2.1 Introduction	34
2.2 Formulation du problème	35
2.3 Méthodes proposées pour l'identification aveugle des filtres	38
2.3.1 Méthode des relations croisées CR	38
2.3.2 Méthode des relations croisées symétrique SCR	41
2.3.3 Méthode SCR robuste (R-SCR)	42
2.4 Résultats et discussion	45

2.4.1	Étude des performances des méthodes proposées d'identification du canal (SCR et R-SCR)	45
2.4.2	Évaluation des performances d'identification du canal pour la restauration d'images (deblurring)	47
2.5	Conclusion	48
3	Restauration d'images par le décodeur séquentiel 'Stack'	51
3.1	Introduction	52
3.2	Formulation du problème	53
3.3	Description du décodeur séquentiel Stack	56
3.3.1	Algorithme 'Stack'	56
3.3.2	Améliorations de l'algorithme Stack	58
3.4	Modèle adopté pour la régularisation	60
3.5	Restauration d'images par descente du gradient	63
3.6	Restauration d'images dans le cas d'un système mono-canal (SISO)	64
3.7	Résultats et discussion	66
3.7.1	Evaluation de la version améliorée de l'algorithme Stack	67
3.7.2	Évaluation de la qualité de restauration par l'algorithme Stack	70
3.7.3	Résultats de la restauration par l'algorithme régularisé Stack-TV	71
3.7.4	Amélioration de la restauration par la descente du gradient	72
3.7.5	Étude comparative des algorithmes Stack-TV et ADMM-TV	74
3.7.6	Restauration d'images dans un contexte mono-canal (cas bruité)	74
3.8	Conclusion	75
4	Restauration d'images avec critères orientés qualité	77
4.1	Introduction	78
4.2	Notations et formulation du problème	79
4.2.1	Modèle de dégradation et de restauration de l'image	80
4.2.2	Cadre général de l'algorithme ADMM	81
4.3	Métriques d'évaluation de la qualité d'images	83
4.3.1	Description de l'indice de SIMilarité Structurale (SSIM)	84
4.4	Algorithme proposé pour la restauration d'image avec critère orienté qualité	86
4.4.1	Optimisation par descente du gradient	86
4.4.2	Description du critère basé sur les mesures de qualité	87
4.5	Résultats et discussion	88
4.5.1	Performance de la restauration avec la minimisation du critère basé qualité	89
4.5.2	Impact d'utilisation de l'indice SSIM	90
4.6	Conclusion	95
5	Séparation aveugle d'images	96
5.1	Introduction	97
5.2	Formulation du problème de séparation d'images	98
5.3	Description des algorithmes de séparation aveugle d'images	99
5.3.1	Algorithme de séparation basé sur les statistiques du second ordre	100

5.3.2	Algorithme de séparation basé sur la représentation parcimonieuse des sources	101
5.4	Approches proposées pour la séparation aveugle d'images	104
5.4.1	Approche duale pour la séparation aveugle d'images	105
5.4.2	Approche hybride pour la séparation aveugle d'images	106
5.5	Résultats et discussion	108
5.5.1	Évaluation de la performance de l'approche duale de séparation . . .	109
5.5.2	Séparation aveugle d'images basée sur la minimisation d'un critère hybride	112
5.5.3	Séparation aveugle d'images médicales	114
5.6	Conclusion	114
Conclusion et perspectives		118
Bibliographie		121

Table des figures

1.1	Les différentes métriques objectives d'évaluation de la qualité d'images. . .	23
2.1	Un système avec une entrée inconnue et une fonction de système inconnue.	34
2.2	Réponses fréquentielles des différents filtres dégradants utilisés, (a) Flou de bouger de 7 pixels dans la direction 40 degrés, (b) Flou moyenneur de taille (5×5) , (c) Flou Gaussien de taille (5×5) et de variance 1.5 et (d) Flou de type disque de rayon 5.	36
2.3	Les $K = 4$ images dégradées par les différents filtres présentés précédemment à la figure 2.2.	37
2.4	Les $K(K - 1)/2$ paires possibles pour l'algorithme CR. Exemple pour $K = 4$.	39
2.5	Les K paires possibles pour l'algorithme SCR, construites pour $K = 4$ images observées.	41
2.6	Parcimonie de la fonction de flou ($m_h = n_h = 3$) avec surestimation de l'ordre ($\tilde{m}_h = \tilde{n}_h = 5$).	43
2.7	NMSE des méthodes CR et SCR en fonction du nombre de canaux.	45
2.8	Évolution de l'erreur d'estimation des canaux en fonction du nombre d'itérations.	46
2.9	Performances de la méthode R-SCR avec surestimation de l'ordre du canal.	47
2.10	Erreur d'identification en fonction de l'ordre de surestimation.	48
2.11	Comparaison des performances des méthodes CR et SCR pour la restauration d'images : (a, b) : $K = 4$ et $SNR = 20\text{dB}$, (c, d) : $K = 8$ et $SNR = 25\text{dB}$	49
2.12	Performances des méthodes SCR et R-SCR pour la restauration d'images avec surestimation de l'ordre du canal.	50
3.1	Schéma bloc de la dégradation/restauration d'images d'un système SIMO.	54
3.2	Exemple d'arborescence pour $(K = 4)$ niveaux.	57
3.3	Mécanisme du décodage par l'algorithme Stack.	58
3.4	Structure à bande limitée de la matrice de filtrage \mathbf{R}	59
3.5	Modèle de restauration d'images dans un contexte mono-canal.	65
3.6	Images utilisées pour l'approche hiérarchique et dégradées par trois types de flou.	68
3.7	Restauration d'images avec l'approche hiérarchique avec 32 classes ($N = 5$). Image originale, grossière et raffinée (de gauche à droite).	69
3.8	(A, B, C, D) : Images floues. (A', B', C', D') : Images restaurées à l'aide de l'algorithme proposé.	71

3.9	(A, B, C, A', B', C') : Images floues bruitées, (D, D') : Résultats de la restauration dans le cas multi-canal.	72
3.10	(A, A') : Images restaurées sans régularisation, (B, B') : Images restaurées avec régularisation ℓ_1 , (C, C') : Images restaurées avec régularisation ℓ_2 . . .	73
3.11	Résultats d'amélioration de la qualité de restauration avec l'approche proposée, (A, B) : Stack-TV ℓ_2 , (A', B') : Descente du gradient.	73
3.12	(A, B) : Résultat de la restauration mono-canal (sans régularisation), (A', B') : Restauration multi-canal (sans régularisation).	75
4.1	Système de mesure de l'indice SSIM (Wang et al., 2005).	85
4.2	Amélioration de la restauration d'image dans le cas non bruité (ADMM-TV (rouge) suivi par la descente du gradient (bleu)).	89
4.3	Résultat de la restauration de l'image 'synthétique' par l'algorithme proposé (avec critère qualité).	91
4.4	Résultat de la restauration de l'image 'Pirate' par l'algorithme proposé (avec critère qualité).	92
4.5	Résultat de la restauration sans information <i>a priori</i> (Mesure globale de qualité).	93
4.6	Résultat de la restauration sans information <i>a priori</i> (Mesure locale de qualité).	94
5.1	Principe de l'approche duale pour la séparation aveugle d'images, (a) WASOBI suivie par ISBS et (b) ISBS suivie par WASOBI.	105
5.2	Deux images sources (a)-(b) avec leurs mélanges naturels (c)-(d) et leurs mélanges parcimonieux (e)-(f) obtenus à l'aide de la transformée de Laplace.	110
5.3	Performances de l'approche duale de séparation (résultat de l'algorithme ISBS (a)-(b) suivi de l'amélioration par l'algorithme WASOBI (c)-(d)). Le cercle rouge indique les défauts et imperfections de la séparation. Le cercle vert montre l'amélioration obtenue.	111
5.4	Performance de l'approche duale de séparation (résultat de l'algorithme WASOBI (a)-(b). Amélioration obtenue par application successive de l'algorithme ISBS (c)-(d).	112
5.5	Résultats de séparation aveugle d'images en utilisant l'approche hybride proposée (e)-(f), comparés aux images restaurées par l'algorithme WASOBI (a)-(b) et aux images restaurées par l'algorithme ISBS (c)-(d).	113
5.6	Mélange d'images médicales (c)-(d), résultats de la séparation avec l'approche hybride proposée (e)-(f).	116
5.7	Mélange d'images médicales avec des scans axiaux (c)-(d), résultats de la séparation avec l'approche hybride proposée (e)-(f).	117

Liste des tableaux

3.1	Gain en coût de calcul de l'algorithme Stack avec utilisation de la structure BL.	68
3.2	Évolution du coût de calcul en fonction de l'élargissement de recherche (étape raffinée).	69
3.3	Évolution de la qualité de restauration en fonction de l'élargissement de recherche (étape raffinée).	70
3.4	Comparaison des performances des algorithmes Stack, Stack-TV(ℓ_1), Stack-TV(ℓ_2) et Stack-GD.	74
4.1	Images dégradées utilisées pour les expériences.	88
4.2	Comparaison des résultats de la restauration par l'algorithme proposé avec critère qualité.	90
4.3	Amélioration de la qualité avec utilisation du SSIM sans information <i>a priori</i> (mesure globale de qualité).	91
4.4	Amélioration de la qualité avec utilisation du SSIM sans information <i>a priori</i> (mesure locale de qualité).	93
4.5	Résultats de la restauration avec intégration complète d'information <i>a priori</i>	94
5.1	Évaluation des performances de l'approche duale proposée pour les deux sources images, Cameraman (S1) et Parrot (S2).	111

Liste des Algorithmes

1	Identification aveugle des filtres dégradants (PSFs)	44
---	--	----

Introduction générale

Dans la vie scientifique moderne, les images de haute qualité sont devenues omniprésentes dans différents domaines. Dans certaines applications la présence d'un ensemble de facteurs (liés au capteur d'acquisition, chaîne de transmission, les conditions de prise de vue, etc.) affectent la qualité de ces images. À cet effet, une ou plusieurs versions dégradées de la même image originale proviennent chacune via un canal différent. Cette diversité des canaux est fortement liée à la fonction de flou (filtre dégradant) qui caractérise chaque canal, nommée fonction d'étalement d'un point (PSF : Point Spread Function). En plus de la dégradation causée par le flou, le bruit sous ses diverses formes et sources (bruit de capteur, bruit d'amplification, bruit dû aux photons, etc.) s'introduit dans le processus et affecte aussi l'image. Ainsi, les images observées représentent une version à la fois floues et bruitées de la scène.

Pour surmonter le problème de ces imperfections et limitations, le domaine de la restauration d'images a connu un essor fulgurant grâce à l'intérêt accordé par la communauté scientifique à cet axe de recherche. La restauration est un problème inverse '**mal-posé**' qui a pour objectif d'estimer l'image la plus nette possible à partir d'images dégradées. Dans le cas où le processus de dégradation est méconnu sans connaissance a priori, le problème devient 'doublement mal-posé' et la restauration se fait dans un contexte dit 'aveugle'. D'autre part, ce problème de restauration est aussi inverse '**mal-conditionné**' et requiert l'exploitation de toute information disponible et apportée par les différentes observations. En effet, généralement dans le contexte multi-canal, en respectant certaines conditions d'indépendance des canaux, la qualité de la restauration est meilleure et la convergence est plus stable que dans le cas mono-canal.

Ce problème de restauration d'images dans un contexte multi-canal aveugle est examiné

dans notre travail. Pour cela, l'approche adoptée, porte tout d'abord, sur l'identification aveugle des filtres dégradants caractérisant les canaux d'un système à entrée unique et sorties multiples (SIMO : Single Input Multiple Output). Cette identification est articulée essentiellement sur la méthode des relations croisées. Les filtres estimés sont par la suite exploités afin de reconstruire l'image originale à l'aide d'un algorithme séquentiel décrit comme étant une recherche arborescente dans l'alphabet des niveaux de gris de l'image [0, 255].

Vu que le progrès a largement touché tous les domaines du traitement d'images, l'évaluation de la qualité de ces images est souvent utilisée afin de corréler le résultat à l'appréciation visuelle de l'humain. D'autre part, le processus de restauration d'images est souvent assuré par une optimisation d'une fonction de coût par le biais de l'estimateur du maximum de vraisemblance. Dans le cas où le bruit est gaussien, la restauration est faite à l'aide d'une minimisation au sens des moindres carrées. À cet égard, les métriques d'évaluation de la qualité d'images sont utilisées dans notre travail, comme terme constituant du critère global à minimiser. Ces métriques jouent ainsi le rôle d'un terme pondéré de régularisation afin de mieux affiner la qualité des images restaurées.

Par ailleurs, les techniques de séparation de sources dans un contexte multi-canal aveugle peuvent être considérées comme des approches de restauration d'images. Ces méthodes ont connu un grand intérêt dans les applications du traitement du signal (1D) étendu au domaine du traitement d'images (2D). Leurs objectifs principaux sont, de séparer (restaurer) deux ou plusieurs sources (images) originales à partir seulement d'un mélange d'images observé. Ainsi, le mélange est généralement considéré comme étant un mélange de sources, instantané ou convolutif, linéaire ou non linéaire.

Structure du manuscrit

Ce manuscrit est organisé en cinq chapitres :

Chapitre 1 : Dans ce chapitre, nous présentons un état de l'art qui englobe les différentes méthodes de restauration aveugle d'images dans le cas d'une ou de plusieurs observations. Ce travail de lecture et de recherche bibliographique est divisé en quatre

parties principales :

- Techniques d'identification aveugle d'un système afin d'estimer les filtres dégradants,
- Techniques de restauration d'images dans les contextes mono et multi-canal,
- Techniques d'évaluation de la qualité des images,
- Techniques dédiées à la séparation aveugle de sources images linéairement mélangées.

Chapitre 2 : Nous présentons ici une technique d'identification aveugle pour un système à entrée unique et sorties multiples où l'ordre du canal est inconnu (surestimé). Tout d'abord, une version simplifiée, c-à-d à coût réduit (dite SCR : Symmetric Cross Relations) de la méthode des relations croisées (CR : Cross Relations) pour l'identification aveugle SIMO est introduite. Celle-ci permet de réaliser un bon compromis entre complexité numérique et performance d'estimation. Ensuite, une version robuste (dite R-SCR : Robust-Symmetric Cross Relations) basée sur la recherche d'une solution parcimonieuse minimisant la fonction de coût CR est proposée.

Chapitre 3 : Après avoir identifié les canaux, la restauration d'images est ensuite assurée par une nouvelle approche inspirée des techniques de décodage de signaux de communications numériques (1D) et étendue ici au cas de la restauration d'images (2D). Celle-ci se base sur une recherche arborescente efficace (algorithme de décodage 'Stack'). Plusieurs versions de l'algorithme 'Stack' sont proposées afin de réduire sa complexité et améliorer la qualité de restauration lorsque les images sont fortement bruitées.

Cette amélioration est garantie, tout d'abord, par l'ajout d'un terme de régularisation au critère de restauration en utilisant la variation totale (Stack-TV). Ensuite, nous développons une approche d'optimisation simple et efficace (dite *all-at-once*) basée sur une simple technique de descente du gradient qui permet de raffiner l'image estimée et d'approcher au mieux la solution optimale.

Chapitre 4 : Les mesures de la qualité d'images sont souvent utilisées pour évaluer et comparer la qualité de la restauration. Dans ce chapitre, nous proposons de les utiliser comme fonctions de coûts (intégrées dans le critère global à optimiser) et ceci afin d'étudier leur potentiel pour améliorer les performances de restauration. La

mesure choisie est l'indice de similarité structurelle (SSIM : Structural SIMilarity) qui est l'une des métriques les plus appropriées car relativement simple à calculer et inspirée du système visuel humain (HVS : Human Visual System).

Chapitre 5 : Dans le cas où l'image d'intérêt est corrompue par d'autres images interférentes (c-à-d mélange instantané d'images), sa restauration nécessite le recours aux techniques de séparation aveugle de sources que nous traitons dans ce chapitre. Dans ce contexte, nous réalisons une étude comparative de certaines techniques de séparation d'images, basées sur deux propriétés : la décorrélation au second ordre (indépendance statistique des sources) et/ou la parcimonie, via un critère 'hybride' ou 'dual'.

Une conclusion générale ainsi que des perspectives sont données à la fin de ce manuscrit.

Liste de publications et communications

Ce travail de thèse a donné lieu à un certain nombre de publications :

Actes de conférences internationales publiés

1. Boudjenouia, F., Jennane, R., Abed-Meraim, K., and Chetouani, A. (2016c). Sequential stack decoder for multichannel image restoration. In *Signal Processing Conference (EUSIPCO), 2016 24th European*, pages 1293–1297. IEEE (**Chapitre 3**)
2. Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2016a). On the use of all-at-once optimization technique for image restoration quality improvement. In *Proceedings of The First International Conference of High Innovation in Computer Science*, pages 159–162 (**Chapitre 3**), (**Chapitre 4**).
3. Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2016b). On the use of image quality measures for image restoration. In *Image Processing Theory Tools and Applications (IPTA), 2016 6th International Conference on*, pages 1–6. IEEE (**Chapitre 4**)
4. Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2017). Identification aveugle 2d robuste à la surestimation de l'ordre. In *Image and Signal Processing and their Applications (ISPA 2017)*. ISPA (**Chapitre 2**)

Article de journal soumis

1. Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2018b). Blind multichannel image restoration using stack decoder. *à soumettre dans IET Image Processing* (**Chapitres 2 et 3**), texte disponible.
2. Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2018a). Blind image separation using composite criteria based on statistical information and sparse representation. *à soumettre prochainement* (**Chapitre 5**), texte disponible.

Chapitre 1

État de l'Art

Sommaire

1.1	Introduction	7
1.1.1	Formulation mathématique du problème	7
1.2	Identification aveugle des systèmes	8
1.2.1	Diversité des canaux et conditions d'identifiabilité	9
1.2.2	Les méthodes sous-espaces	10
1.2.3	La méthode du maximum de vraisemblance	12
1.3	Restauration multi-canal d'images	13
1.3.1	Classification des méthodes de la restauration d'images, selon l'étape d'identification	14
1.3.2	Méthodes non-aveugle de restauration d'images	15
1.3.3	Méthodes de restauration aveugle d'images	16
1.3.4	Autres méthodes et approches de restauration d'images	19
1.4	Évaluation de la qualité des images	19
1.4.1	Classification des méthodes IQA	20
1.4.2	Métriques d'évaluation perceptuelle de la qualité d'image	23
1.5	Séparation aveugle de sources images	26
1.5.1	Techniques classiques de décomposition	26
1.5.2	Méthodes statistiques du second ordre pour la BSS	28
1.5.3	Méthodes des statistiques d'ordre supérieur pour la BSS	30
1.6	Conclusion	32

1.1 Introduction

Ce chapitre est consacré à la présentation des techniques et méthodes utilisées pour la restauration aveugle d'images. Il est décliné en quatre volets. Le premier volet concerne l'identification aveugle des systèmes dans un contexte multi-canal où un bref aperçu est donné des méthodes sous-espaces, méthodes des moments et les méthodes de maximum de vraisemblance. Le deuxième volet est consacré à l'étude des techniques de restauration d'image où une classification englobante des différents algorithmes (aveugle et non-aveugle) est décrite. Le troisième volet illustre l'intérêt de l'évaluation de la qualité des images, soit en la considérant comme des métriques pour des fins de comparaison des résultats ou comme un terme de la fonction de coût à minimiser. Finalement, le quatrième volet décrit les notions de base de la séparation aveugle d'images à partir de mélanges.

1.1.1 Formulation mathématique du problème

La restauration aveugle d'images est le processus d'estimation à la fois de l'image originale et du flou à partir des caractéristiques des images dégradées en utilisant des informations partielles sur le système d'imagerie. Dans les travaux de la restauration linéaire d'images, la fonction de flou est souvent donnée, et le processus de dégradation est inversé en utilisant l'un des nombreux algorithmes connus pour la restauration. Les différentes approches évoquées dans la littérature dépendent des modèles particuliers de la dégradation et celui de l'image (Katsaggelos, 2012; Banham and Katsaggelos, 1997).

Dans de nombreuses applications d'imagerie, une image observée \mathbf{g}_i de taille $(m_g \times n_g)$ peut être modélisée comme étant la convolution bidimensionnelle de l'image originale \mathbf{f} de taille $(m_f \times n_f)$ avec un flou linéaire invariant en décalage, connu sous le nom de fonction d'étalement d'un point (PSF : Point Spread fonction), \mathbf{h}_i de taille (m_h, n_h) .

À savoir que notre système possède un seul canal SISO ($i = 1$) ou plusieurs canaux indépendants SIMO ($i = 1, \dots, K$; $K > 2$). L'image observée peut être exprimée pour

chaque pixel (m, n) dans le cas d'un système SIMO (multi-canal), comme suit :

$$\begin{aligned} g_i(m, n) &= h_i(m, n) \star f(m, n) + w_i(m, n) \quad (i = 1, \dots, K) \\ &= \sum_{l_1=0}^{m_h-1} \sum_{l_2=0}^{n_h-1} h_i(l_1, l_2) f(m - l_1, n - l_2) + w_i(m, n) \end{aligned} \quad (1.1)$$

où (\star) désigne l'opérateur linéaire de la convolution bidimensionnelle et w_i de taille $(m_g \times n_g)$ désigne le bruit additif pour chaque canal. Notons que pour des raisons de simplicité des notations, nous avons adopté une représentation causale des filtres PSF.

Une technique de vectorisation des images dégradées g_i est sollicitée dans le cas multi-canal afin de reformuler l'expression du processus de dégradation sous forme d'un produit matrice-vecteur :

$$\begin{aligned} \mathbf{g} &= [\mathbf{g}_1^T, \mathbf{g}_2^T, \dots, \mathbf{g}_K^T]^T \\ &= \mathbf{H} \mathbf{f} + \mathbf{w} \end{aligned} \quad (1.2)$$

où $\mathbf{g}_i = \text{vec}(g_i)$ est la version vectorisée colonne par colonne de la $i^{\text{ième}}$ image dégradée, puis tous les vecteurs \mathbf{g}_i ($i = 1, \dots, K$) sont empilés dans un seul vecteur d'observations \mathbf{g} . Pareil pour l'image originale et le bruit, leur versions vectorisées sont données par les vecteurs \mathbf{f} et \mathbf{w} . $\mathbf{H} = [\mathbf{H}_1^T, \dots, \mathbf{H}_K^T]^T$ est la matrice de convolution dont l'élément \mathbf{H}_i de taille $(m_f + m_h - 1)(n_f + n_h - 1) \times m_f n_f$ est représenté sous forme d'une matrice Toeplitz par bloc avec des blocs Toeplitz associée à la PSF h_i . Cette représentation sera requise dans la suite de nos travaux (voir la section 3.2 pour plus de détails sur la construction de la matrice \mathbf{H}).

Dans la section suivante, nous décrivons les différentes techniques et approches développées pour l'identification aveugle des fonctions de flou dans le cas d'un système SIMO.

1.2 Identification aveugle des systèmes

L'identification aveugle d'un système multi-canal (BSI) est une technique qui permet d'estimer à la fois l'entrée et la fonction inconnue du canal à partir des mesures simulta-

nées de différents canaux par lesquels le signal d'entrée se propage. Dans cette section, un résumé des algorithmes récents d'estimation aveugle des canaux est présenté. Nous présentons tout d'abord les conditions d'identifiabilité des canaux, les méthodes sous-espaces en citant l'approche du sous-espace bruit et l'approche des relations croisées. Ensuite, nous décrivons également la méthode du maximum de vraisemblance.

1.2.1 Diversité des canaux et conditions d'identifiabilité

En général, un système est considéré comme étant complètement identifiable si tous les paramètres inconnus du système peuvent être déterminés de manière unique, à une constante près dans le cas aveugle. En particulier, il est démontré dans [Harikumar and Bresler \(1999a\)](#) que dans le cas multi-canal sans bruit, il est possible d'obtenir une identification exacte des canaux à partir d'un ensemble fini d'observations. Toutefois, ce résultat nécessite la satisfaction de certaines conditions concernant les canaux pour assurer l'identifiabilité et l'unicité des solutions.

L'identifiabilité d'un système multi-canal et l'unicité des filtres de la restauration dépendent essentiellement du rang (colonne) plein de la matrice de filtrage \mathbf{H} . Cette dernière dépend à son tour des fonctions de transfert (polynômes à deux variables) $\mathcal{H}_i(z_1, z_2)$ des filtres dégradants \mathbf{h}_i , exprimées comme suit :

$$\mathcal{H}_i(z_1, z_2) = \sum_{l_1=0}^{m_h-1} \sum_{l_2=0}^{n_h-1} h_k(l_1, l_2) z_1^{-l_1} z_2^{-l_2} \quad \forall i = 1, \dots, K \quad (1.3)$$

Une condition nécessaire pour l'identifiabilité 'exacte' est que les polynômes \mathcal{H}_i soient premiers entre eux. Autrement dit, il n'existe pas un zéro commun à toutes les fonctions de transfert c'est-à-dire qu'il n'existe pas (ζ_1, ζ_2) tel que :

$$\mathcal{H}_i(\zeta_1, \zeta_2) = 0 \quad \forall i = 1, \dots, K \quad (1.4)$$

1.2.2 Les méthodes sous-espaces

De nombreuses techniques récentes d'identification aveugle de canaux exploitent des structures algébriques et représentent les observations via des sous-espaces appropriés. L'originalité des méthodes sous-espaces vient du fait qu'elles exploitent la séparation (propriété d'orthogonalité) entre le sous-espace du signal \mathbf{U}_s et celui du bruit \mathbf{U}_n .

Ces méthodes ont la propriété que l'identification des canaux peut souvent être obtenue via l'optimisation d'un critère quadratique (Soudene et al., 2009) :

$$\hat{\mathbf{h}} = \arg \min_{\mathbf{h}} \mathbf{h}^T \mathbf{Q} \mathbf{h} \quad (1.5)$$

où $\mathbf{h} = [\text{vec}(h_1)^T, \text{vec}(h_2)^T, \dots, \text{vec}(h_K)^T]^T$ et \mathbf{Q} est une matrice appropriée construite à partir du sous-espace de bruit \mathbf{U}_n .

Les méthodes sous-espaces ont l'avantage d'être potentiellement déterministes et d'avoir de très bonnes performances d'estimation à moyen et fort SNR (Signal to Noise Ratio). Cependant, elles peuvent ne pas être robustes au mauvais conditionnement des canaux (dû par exemple à une faible diversité) et aussi aux erreurs de modélisation surtout lorsque la matrice de filtrage \mathbf{H} du canal est presque singulière. Le deuxième inconvénient est que ces méthodes sont souvent coûteuses en temps de calcul.

Dans leur version de base, les méthodes sous-espaces nécessitent que le bruit soit blanc centré avec une covariance connue à une constante près $\sigma \mathbf{I}$ et avec un ordre connu (taille du support $m_h \times n_h$) des filtres à identifier. Ce dernier point, pas souvent pratique, a beaucoup retenu l'attention des chercheurs. Pour le résoudre, trois techniques ont été proposées. La première consiste à déterminer l'ordre du canal et estimer séparément les filtres comme dans (Akaike, 1974; Rissanen, 1978; Fishler et al., 2002). La deuxième se base uniquement sur l'estimation de la borne supérieure de l'ordre (Abed-Meraim et al., 1997b). La troisième détecte l'ordre du canal et l'estime conjointement (Tong and Zhao, 1999).

Plusieurs algorithmes sous espaces existent dans la littérature, ci-dessous un bref descriptif :

1. Approche du sous-espace bruit

Cette approche a été proposée et améliorée dans (Moulines et al., 1995) en exploitant directement la structure de la matrice de filtrage \mathbf{H} . Il existe une connexion forte entre l'approche des relations croisées et le sous-espace bruit. L'idée de base est que toutes les images observées $\mathbf{g}(m, n)$ évoluent dans un sous-espace nommé "sous-espace image \mathbf{U}_s " (de dimension d_s) généré par les vecteurs colonnes de \mathbf{H} (qui correspond au sous-espace généré par les vecteurs propres principaux de la matrice d'auto-covariance des observations). Le reste des vecteurs propres génèrent le "sous-espace bruit \mathbf{U}_n " (de dimension d_n). Sous la condition de diversité des canaux mentionnée précédemment, il s'avère que le sous espace image \mathbf{U}_s caractérise de manière unique (à une constante près) le vecteur canal \mathbf{h} que l'on cherche à identifier (Souidene et al., 2009).

L'estimation des canaux est assurée dans ce cas de figure par la résolution du critère des moindres carrés suivant :

$$\hat{\mathbf{h}} = \arg \min_{\mathbf{h}} \sum_{i=1}^{d_n} \|\mathbf{v}_i^T \mathbf{H}\|^2 = \arg \min_{\mathbf{h}} \sum_{i=1}^{d_n} \mathbf{h}^T (\mathbf{v}_i \mathbf{v}_i^T) \mathbf{h} \quad (1.6)$$

où \mathbf{V}_i est une matrice Toeplitz par bloc construite à partir des vecteurs \mathbf{v}_i du sous-espace bruit \mathbf{U}_n associés à ses plus petites valeurs propres. D'où la forme quadratique est donnée par :

$$\mathbf{Q} = \sum_{i=1}^{d_n} \mathbf{v}_i \mathbf{v}_i^T \quad (1.7)$$

L'inconvénient de cette technique est qu'elle est inefficace et nécessite un traitement supplémentaire pour le cas d'une sur-détermination de l'ordre des canaux. Plusieurs versions de cette méthode existent, comme dans (Hua et al., 1997) basé sur une technique de sous-espace bruit minimal introduite afin de réduire la complexité de calcul.

2. Approche des relations croisées :

L'approche des relations croisées exploite judicieusement la structure multi-canal et tire profit de la commutativité du produit de convolution (Hua, 1996). Cet algorithme a été découvert indépendamment sous différentes formes dans plusieurs applications du traitement du signal et des images (Harikumar and Bresler, 1999b; Wirawan et al., 2003).

En considérant le modèle multi-canal sans bruit impliquant des canaux i et j , nous avons simplement pour chaque pixel (m, n) la relation croisée suivante :

$$h_i \star h_j \star f(m, n) = h_j \star h_i \star f(m, n) \quad (1.8)$$

Ce qui correspond dans le cas sans bruit à :

$$h_i \star g_j = h_j \star g_i \quad (1.9)$$

Et sous une forme matricielle, cette relation est donnée par :

$$[\mathbf{g}_i(m, n)^T \quad -\mathbf{g}_j(m, n)^T] \begin{bmatrix} \mathbf{h}_j \\ \mathbf{h}_i \end{bmatrix} = 0 \quad \forall(i, j), \quad \forall(m, n) \quad (1.10)$$

avec $\mathbf{h}_1, \dots, \mathbf{h}_K$, les versions vectorisées de toutes les PSFs h_1, \dots, h_K .

La prise en compte de toutes les $K(K - 1)/2$ relations croisées possibles donne pour tout pixel (m, n) l'équation $\Psi(m, n) \mathbf{h} = 0$. L'estimation du canal passe par la minimisation du critère $\hat{\mathbf{h}} = \arg \min_{\mathbf{h}} \sum_{m,n} \|\Psi(m, n) \mathbf{h}\|_2^2$ qui peut être reformulé selon l'équation 1.5. Dans ce cas de figure, la forme quadratique est calculée comme suit :

$$\mathbf{Q} = \sum_{m,n} \Psi(m, n)^T \Psi(m, n) \quad (1.11)$$

1.2.3 La méthode du maximum de vraisemblance

Un des algorithmes les plus populaires d'estimation est celui basé sur le maximum de vraisemblance (ML : Maximum Likelihood) (Tom et al., 1996). Cette classe d'estimateurs est habituellement asymptotiquement optimale pour un nombre important d'applications. Malheureusement, les méthodes ML contrairement aux approches sous-espaces ne peuvent généralement pas être obtenues sous une forme simple d'optimisation et leurs implémentations s'avèrent compliquées à cause de l'existence de minima locaux. Cependant, elles sont très efficaces si elles sont initialisées par des approches sous-espaces.

Sous l'hypothèse que le bruit additif est blanc gaussien, les estimations ML sont précises et performantes, particulièrement dans les cas à faible SNR, ou lorsque les canaux sont

mal conditionnés (Harikumar and Bresler, 1999b). La formulation de l'estimation ML peut être trouvée dans (Porat and Friedlander, 1991). Le problème à aborder est d'estimer un paramètre déterministe $\boldsymbol{\theta}$ compte tenu du modèle probabiliste des observations. À partir des images observées \mathbf{g} , le paramètre $\boldsymbol{\theta}$ est estimé en maximisant :

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \Upsilon(\mathbf{g}; \boldsymbol{\theta}) \quad (1.12)$$

où $\Upsilon(\mathbf{g}; \boldsymbol{\theta})$ est la fonction de densité de probabilité. Ces méthodes ML peuvent être dérivées en approches statistiques ou déterministes comme suit :

1. Approche statistique du maximum de vraisemblance :

Dans ce cas de figure, l'image originale est supposée aléatoire avec une distribution connue. Le seul paramètre inconnu à estimer est le vecteur des filtres dégradants ($\boldsymbol{\theta} = \mathbf{h}$).

2. Approche déterministe du maximum de vraisemblance :

Cette approche ne considère aucun modèle statistique de l'entrée (image originale). Ici, le vecteur des filtres \mathbf{h} et le vecteur d'entrée \mathbf{f} sont des paramètres à estimer (par exemple pour un modèle gaussien déterministe : $\boldsymbol{\theta} = (\mathbf{h}, \mathbf{f})$ (Katsaggelos and Lay, 1991)).

1.3 Restauration multi-canal d'images

Cette section présente un aperçu sur les développements récents des techniques multi-canal appliquées à la déconvolution 2D ou la restauration d'images. Le problème de la restauration multi-canal d'images est d'obtenir une estimation de l'image originale en tenant compte des images observées de la scène, des fonctions de dégradation et de certaines connaissances sur le bruit de chaque canal. Néanmoins, le problème le plus difficile est celui où les filtres dégradants sont inconnus, c'est-à-dire de travailler dans un contexte aveugle.

Ce problème inverse est mal-posé nécessitant souvent le recours à la régularisation qui garantit une solution unique et une stabilité contre les effets du bruit et de certains désaccords du modèle. Dans la littérature, il existe plusieurs choix pour classer les méthodes de

restauration multi-canal d'images : les méthodes stochastiques ou déterministes, directes ou itératives, linéaires ou non linéaires et aveugles ou non aveugles.

1.3.1 Classification des méthodes de la restauration d'images, selon l'étape d'identification

Nous pouvons classer les approches de restauration en deux catégories, selon que l'on considère une identification 'a priori' ou 'conjointe' des filtres dégradants.

Méthodes avec identification *a priori* du flou

Avec ces approches, le flou est identifié séparément de l'image originale, puis utilisé en combinaison avec l'un des algorithmes classiques de restauration afin de restituer l'image originale. Un modèle paramétrique de flou peut être utilisé dans ce cas de figure, puis l'objectif est d'identifier les paramètres de flou \mathbf{h} à l'aide des observations. Cette approche a été utilisée dans (Stockham et al., 1975; Cannon, 1976) et dans un contexte bayésien dans (Bishop and Hopgood, 2006). En outre, si une bonne compréhension du système d'imagerie est disponible pour une application spécifique, nous pouvons faire une prédiction *a priori* du flou. L'utilisation de cet *a priori* rend la procédure non aveugle et cela est souvent possible en microscopie, en échographie médicale, en télédétection ou pour les télescopes optiques.

Méthodes avec identification conjointe de flou

La majorité des méthodes existantes appartiennent à cette classe, où l'image et le flou sont identifiés simultanément. Toutefois, en pratique, de nombreuses méthodes dans cette catégorie utilisent une approche alternative pour estimer \mathbf{f} et \mathbf{h} plutôt que de trouver réellement la solution. Cependant, une connaissance *a priori* de l'image et du flou est intégrée sous forme de modèles. Les paramètres décrivant ces modèles doivent également être estimés à partir des données disponibles et ceci est souvent effectué avant l'identification du flou et de l'image (Molina et al., 2006).

1.3.2 Méthodes non-aveugle de restauration d'images

Cette classe de techniques de restauration englobe de façon générale les approches de Wiener et les moindres carrés avec contraintes (CLS : Constrained Least Squares) qui reposent sur des modèles stochastiques et déterministes de l'image originale.

La méthode de restauration basée sur le filtrage de Wiener a été proposée par (Hunt and Kubler, 1984) en utilisant la transformation multi-spectrale de Karhunen-Loeve (KL), qui offre une diagonalisation par blocs de la matrice d'auto-corrélation le long de la dimension spectrale. Par la suite, une autre méthode basée sur le filtrage de Wiener a été développée dans (Galatsanos and Chin, 1989) qui calcule récursivement l'inverse de la matrice en blocs, ce qui représente une formulation inverse de la solution de Wiener. D'autre part, une méthode de restauration basée sur une erreur quadratique moyenne contrainte (CMSE : Constrained Mean Square Error) a été introduite dans (Zervakis, 1992) afin de conserver la suppression simultanée du bruit et la préservation des contours.

Filtres multi-canal de Wiener

Une technique de restauration multi-canal d'images basée sur le filtrage de Wiener a été proposée dans (Na and Paik, 1996), en tenant compte de la corrélation et de la méthode d'estimation du spectre correspondant en utilisant les observations dégradées.

Cette méthode peut être résumée comme suit. Tout d'abord, la décorrélation des images observées est effectuée en utilisant les transformations KL. Par la suite, l'image restaurée $\hat{\mathbf{f}}$ est obtenue récursivement par l'inversion d'une matrice $\mathbf{R} = [\mathbf{H}\mathbf{R}_f\mathbf{H}^T + \mathbf{R}_n]$, comme suit (Kang, 1998) :

$$\hat{\mathbf{f}} = \mathbf{R}_f\mathbf{H}^T [\mathbf{H}\mathbf{R}_f\mathbf{H}^T + \mathbf{R}_n]^{-1} \mathbf{g} \quad (1.13)$$

avec \mathbf{R}_f et \mathbf{R}_n , les matrices d'auto-corrélation de \mathbf{f} et du bruit \mathbf{n} , respectivement.

L'inconvénient de cette approche est qu'elle nécessite des connaissances *a priori* sur le bruit et l'image originale, souvent non disponibles et conduit automatiquement à une perte en qualité de restauration.

Filtres CLS multi-canal

Cette approche a été proposée par (Kang, 1998) pour la restauration multi-canal d'images en se basant sur un filtrage des moindres carrés avec contrainte. L'approche reconstruit l'image originale de manière directe ou itérative. Ainsi, la méthode CLS présente de nombreux avantages vis-à-vis du bruit et garantit l'estimation de l'image originale et des paramètres de régularisation simultanément.

Cette méthode CLS est généralement plus facile à mettre en œuvre par rapport au filtre de Wiener. Par contre, elle est fortement dépendante, en termes de performances, du choix des contraintes. Par la suite, plusieurs techniques ont été développées afin d'améliorer les performances de la méthode CLS (Zhu et al., 2009).

1.3.3 Méthodes de restauration aveugle d'images

La restauration aveugle d'images est un processus qui consiste à identifier à la fois l'image originale et les fonctions de flou à partir des images observées, en utilisant des informations partielles sur le système d'imagerie. Contrairement aux techniques linéaires classiques de restauration, ce processus est discutable car les filtres dégradants sont souvent inconnus dans de nombreuses applications.

Dans la littérature, les algorithmes de restauration aveugle multi-canal sont soit :

1. Des extensions des techniques mono-canal de restauration aveugle d'images (Tom et al., 1996) où deux classes populaires sont distinguées. Une classe utilise des modèles stochastiques pour : l'image originale, la fonction de flou et le bruit. À l'aide des algorithmes comme EM (Expectation Maximization) et GCV (Generalized Cross Validation), ces paramètres sont estimés et par conséquent l'image originale est restaurée (Schulz, 1993). La deuxième classe impose des contraintes déterministes telles que la non-négativité et le support fini sur l'image originale et/ou la fonction de flou et l'estimation se fait itérativement et simultanément (Miura and Baba, 1995).
2. Des extensions des techniques de déconvolution aveugle multi-canal dédiées au traitement du signal 1D à l'aide des approches algébriques souvent utilisées dans les communications numériques (Giannakis and Heath, 2000; Harikumar and Bresler,

1999b; Pai and Bovik, 2001). Ces techniques sont plus récentes et offrent d'excellentes performances sous réserve de bon SNR.

Restauration d'images par maximum de vraisemblance (ML-EM)

Plusieurs travaux dans la littérature proposent d'appliquer l'algorithme EM pour la restauration multi-canal au sens du maximum de vraisemblance (Schulz, 1993; Tom et al., 1996). Dans (Schulz, 1993), l'image originale et le flou inconnu sont supposés déterministes et le bruit additif est modélisé par une distribution de Poisson. L'idée principale de la restauration ML est que θ doit être déterminé de telle sorte que la probabilité d'observer les images floues $[\mathbf{g}_1, \dots, \mathbf{g}_K] \in \mathbf{G}^K$ est maximisée. Ainsi, θ doit maximiser la fonction de vraisemblance suivante :

$$\mathcal{L}_{\mathbf{G}}([\mathbf{g}_1, \dots, \mathbf{g}_K]; \theta) = \Upsilon_{\mathbf{G}}([\mathbf{g}_1, \dots, \mathbf{g}_K]|\theta) \quad (1.14)$$

où $\Upsilon_{\mathbf{G}}([\mathbf{g}_1, \dots, \mathbf{g}_K]|\theta)$ est la fonction de densité de probabilité des K images dégradées. Par conséquent, l'image restaurée peut être obtenue à partir de θ et ceci en utilisant l'algorithme EM qui se compose de deux étapes calculées itérativement. L'algorithme EM peut être décrit comme suit :

Initialisation de $\theta_0 \longrightarrow$ étape **E**stimation \longrightarrow étape **M**aximisation $\longrightarrow \theta_1 \longrightarrow \dots$

Les avantages de cette technique sont que la convergence est garantie et sa complexité calculatoire est relativement faible ($O(Km_h n_h m_f n_f)$). Néanmoins, l'inconvénient de cet algorithme est la convergence vers l'optimum local, ce qui implique que l'initialisation est très cruciale.

Méthode itérative basée sur des contraintes déterministes

Les auteurs de (Miura and Baba, 1995) ont étendu un algorithme itératif de restauration aveugle d'images développé dans le cas 1D par (Ayers and Dainty, 1988) dans un contexte multi-canal. Comme dans le cas 1D, les contraintes de non-négativité sont appliquées sur l'image et les fonctions de flou. Comme une contrainte supplémentaire, les auteurs supposent que les images dégradées proviennent de la même image originale.

Dans le domaine de Fourier, cette méthode sollicite un filtrage de type Wiener afin d'estimer les transformées de Fourier de \mathbf{f} et \mathbf{h} en minimisant un certain critère dit 'fonction d'évaluation'. Le principal avantage de cet algorithme est sa flexibilité avec un faible coût de calcul. Comme inconvénients, il souffre d'une sensibilité élevée à l'initialisation et possède de mauvaises propriétés de convergence.

Méthodes algébriques de restauration aveugle d'images

Cette approche algébrique a été développée par (Harikumar and Bresler, 1999a,b) pour estimer la réponse impulsionnelle dans le cas multi-canal en proposant deux algorithmes : la technique sous-espaces et la technique ML. Ensuite, une approche similaire a été développée par (Giannakis and Heath, 2000) pour réaliser une parfaite estimation des filtres de restauration. Les travaux de (Tong et al., 1994) ont motivé l'émergence pratique de ces techniques en montrant que l'estimation aveugle multi-canal est possible sans certaines contraintes restrictives à l'aide des statistiques de second ordre. Ainsi, pour le problème de déconvolution aveugle multi-canal d'images et le débruitage, une méthode efficace basée sur les égaliseurs mutuellement référencés (MRE : Mutually Referenced Equalizers) a été proposée dans (Souidene et al., 2004).

Pour ces approches algébriques, deux scénarios différents de convolution concernant l'image originale \mathbf{f} et les images observées \mathbf{g} peuvent être considérés :

1. Modèle à données complètes : L'image observée a la même taille ou une taille plus grande que l'image originale, c'est-à-dire $(m_f + m_h - 1, n_f + n_h - 1)$;
2. Modèle à données partielles : L'image observée a une taille inférieure à l'image originale, c'est-à-dire $(m_f - m_h + 1, n_f - n_h + 1)$.

Les approches classiques (multi-canal ou mono-canal) utilisent implicitement un scénario à données complètes (Zero padding) de sorte que la matrice de dégradation soit carrée, alors que les approches algébriques utilisent généralement un modèle à données partielles. Ces techniques algébriques peuvent être classées comme suit :

1. Méthodes d'estimation des canaux (fonctions de flou), puis utilisation d'un algorithme de restauration d'images classique,
2. Méthodes d'estimation du filtre de restauration (vecteur de taille $K \times 1$),

1.4. ÉVALUATION DE LA QUALITÉ DES IMAGES

3. Méthodes directes d'estimation de l'image originale.

Les approches algébriques offrent trois avantages principaux :

1. Aucune image initiale n'est requise,
2. Il n'y a aucun problème de convergence ou de stabilité,
3. Les contraintes sur l'image originale et les fonctions de flou sont relâchées et maintenues de manière générique.

1.3.4 Autres méthodes et approches de restauration d'images

Nous résumons dans cette section d'autres techniques récemment développées pour la restauration d'images. Nous distinguons des techniques probabilistes comme la déconvolution dans un cadre bayésien ou selon un processus Markovien discret, etc. (Pham et al., 2011; Chickerur and Kumar, 2008); ou encore d'autres méthodes qui passent par le domaine fréquentiel via la transformée de Fourier, la transformée en Cosinus, etc. (Bi and Wang, 2008; Araujo et al., 2009; Xue and Wu, 2012); ou par le domaine spatial via la transformée en ondelettes (Srivastava et al., 2009). Ainsi, les réseaux de neurones ont été sollicités dans plusieurs travaux de restauration (Katsaggelos, 2012), de même pour les techniques récentes et les outils conventionnels d'optimisation avec un grand champ d'intérêts et d'applications destinés à la restauration d'images.

Il convient de noter que chacune de ces méthodes a montré ses avantages pour la restauration d'images et aussi souffre d'inconvénients ce qui conduit toujours à combiner ces approches d'une façon 'duale' ou 'hybride' afin d'avoir le système le plus complet et idéal en termes de qualité de restauration ou d'estimation. Cette dernière est généralement quantifiée et mesurée à l'aide des outils et des mesures de qualité qui se rapprochent de la perception visuelle humaine que nous allons présenter dans la section suivante.

1.4 Évaluation de la qualité des images

Aujourd'hui nous sommes assez loin d'obtenir un modèle informatique précis d'un système visuel humain (HVS : Human Visual System) et ceci malgré les développements

et les progrès atteints sur les connaissances d'un tel système. Donc il est particulièrement important et nécessaire de mener des évaluations expérimentales subjectives des approches informatiques qui intègrent les modèles HVS pour les juger et les valider proprement.

La qualité d'image a suscité un intérêt depuis l'invention des instruments optiques qui remontent au début du XVIIe siècle (Keelan, 2002). Son plus grand intérêt était dans les applications du traitement d'images avec l'introduction de la photographie et de la télévision (Pedersen and Hardeberg, 2012). Habituellement, dans le traitement des images, nous sommes intéressés par l'extraction de la qualité perçue d'une image numérique. La façon la plus naturelle pour l'obtenir est de se baser sur le jugement de plusieurs observateurs. C'est un processus subjectif qui résulte en une diversité d'estimations de la qualité.

Dans cette section, nous décrivons les métriques de qualité qui ont été largement utilisées surtout pour évaluer les performances des algorithmes dédiés à la restauration d'images. Un aperçu sera présenté sur les différentes métriques qui ont été proposées dans la littérature. Commençant par les métriques classiques (Teo and Heeger, 1994), comme la traditionnelle erreur quadratique moyenne (MSE), qui sont fréquemment insuffisantes pour la comparaison des images et ne reflètent pas vraiment le jugement d'un système HVS. Néanmoins, des nouvelles techniques ont été proposées comme métriques d'évaluation de la qualité d'images (IQM : Image Quality Metrics) dont l'objectif est de modéliser correctement le système HVS dans divers domaines d'application.

1.4.1 Classification des méthodes IQA

L'évaluation de la qualité d'image (IQA : Image Quality Assessment) est une tâche difficile qui s'appuie traditionnellement sur les modèles informatiques du système visuel humain. Récemment, une nouvelle méthodologie d'évaluation basée sur la similarité structurelle des images a été proposée. Cette méthode appelée indice de similarité structurelle (SSIM : Structural SIMilarity index) a été sélectionnée dans notre travail pour l'évaluation expérimentale (Wang et al., 2004).

La qualité d'une image n'est pas seulement liée à la perception visuelle, mais il y a aussi une dépendance à l'application et à l'usage. Au cours des dernières décennies,

1.4. ÉVALUATION DE LA QUALITÉ DES IMAGES

de nombreuses méthodes dédiées à l'IQA ont été étudiées et proposées. Ces techniques peuvent être classées en deux grandes catégories : les techniques subjectives et objectives.

Méthodes subjectives d'évaluation de la qualité

Les techniques subjectives sont considérées comme les moyens les plus fiables pour évaluer la qualité d'images. Leurs résultats reflètent exactement l'avis des observateurs humains. L'atout est de faire appel à un groupe d'observateurs humains afin d'évaluer la qualité d'une séquence en respectant une procédure précise.

À cette fin, les procédures et recommandations pour l'évaluation sont bien définies et dans la littérature nous trouvons plusieurs exemples de normes et de grilles d'évaluation qui ont été élaborées afin de rendre ces évaluations subjectives les plus objectives possible (par exemple : ITU-R Recommendation BT.500-12, BT.1683, J.144, J.246, J.247, P.910) (Schatz et al., 2013).

Dans ce cas de figure, l'évaluation subjective de la qualité est fortement sensible et dépendante de plusieurs facteurs que nous pouvons brièvement citer, comme suit (BekkatAT, 1999) :

1. La distance d'observation (distance entre 4 à 6 fois la hauteur de l'image),
2. Les conditions de visualisation : éclairage de la salle, couleur de fond,
3. Il est nécessaire de calibrer l'écran de telle sorte à reproduire les couleurs souhaitées,
4. Le choix des images,
5. Les facteurs psychologiques : état psychologique de l'observateur,
6. Le choix des observateurs en fonction de l'application visée, de leur nombre (suffisant), des tests d'acuité visuelle, une diversité intellectuelle, l'âge et aussi la culture, etc.

Méthodes objectives d'évaluation de la qualité

Les métriques objectives d'évaluation de la qualité visent à intégrer une vision de bas niveau et un raisonnement humain de niveau supérieur. Par conséquent, ils correspondent

mieux à la façon dont un observateur humain discriminerait les images. Dans la littérature, l'évaluation objective de la qualité prend habituellement l'une des trois formes suivantes : avec référence complète (FR-IQA), avec référence réduite (RR-IQA) et sans référence (NR-IQA). Cette classification est due principalement à la disponibilité ou non de l'image de référence (image originale).

1. Évaluation de la qualité avec référence complète :

Cette métrique nécessite un accès complet à l'image de référence (originale) et la mesure vise à quantifier la similarité/dissimilarité perçue entre l'image dégradée et l'image originale. Les approches FR-IQA permettent de simuler les propriétés fonctionnelles du système HVS. Cependant, comme la simulation complète du système HVS est trop complexe, seul un nombre limité de propriétés sont prises en compte dans la pratique.

Ces modèles FR-IQA considèrent le système HVS comme étant une boîte noire et ne considèrent que la relation entrée/sortie. Parmi ces métriques nous citons l'indice de similarité structurelle (SSIM) (Wang et al., 2004) et la mesure de fidélité de l'information visuelle (VIF) (Sheikh, 2003).

2. Évaluation de la qualité avec référence réduite :

Les métriques RR-IQA sont initialement conçues pour mesurer la qualité du suivi et/ou du contrôle dans les systèmes de communication (Wang and Bovik, 2006) où certains attributs (descripteurs) clés de l'image de référence pourraient être extraits et envoyés dans un canal auxiliaire et comparés aux mêmes descripteurs extraits de l'image observée.

3. Évaluation de la qualité sans référence :

L'évaluation de qualité d'image sans référence NR-IQA évalue la qualité objective d'une image sans aucune image de référence (complète ou partielle). De toute évidence, le cerveau humain est un exemple idéal de ce type d'approches NR-IQA, ce qui révèle le fait que la connaissance préalable des statistiques d'image naturelle pourrait contribuer de manière significative au développement des métriques NR-IQA.

À l'état actuel, la plupart des systèmes NR-IQA sont conçus pour un type spécifique de distorsion et les hypothèses du processus de distorsion sont des informations très

1.4. ÉVALUATION DE LA QUALITÉ DES IMAGES

essentielles pour la conception de tels systèmes NR-QA (Wang and Bovik, 2011). D'autre part, le NR-IQA à usage général est encore très difficile à réaliser et cela dépendra d'une connaissance approfondie du système visuel humain.

La figure 1.1 montre les différentes métriques objectives de la qualité d'image et leur mécanisme de comparaison entre les images dégradée et originale.

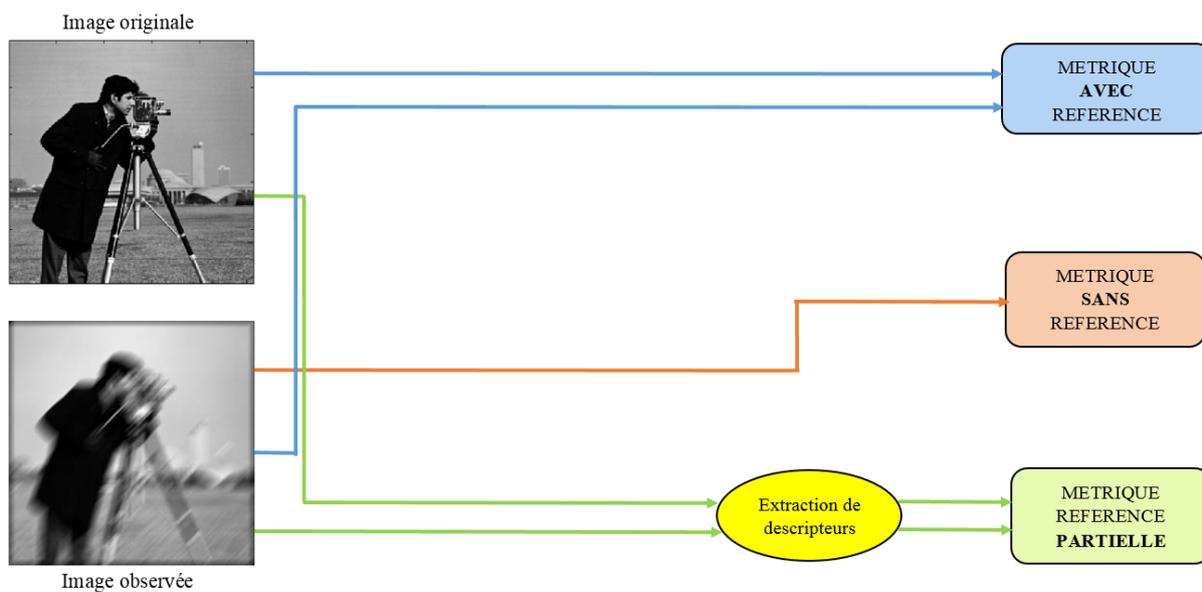


FIGURE 1.1 – Les différentes métriques objectives d'évaluation de la qualité d'images.

Généralement, les métriques avec référence FR-IQA sont utilisées en traitement d'images. Cependant, les deux autres métriques (RR-IQA et NR-IQA) se trouvent dans de nombreuses applications pratiques (Mittal et al., 2013). Pour les lecteurs intéressés, un bref aperçu sur les algorithmes d'IQA sans référence et avec référence réduite est présenté dans (Channappayya et al., 2008a).

1.4.2 Métriques d'évaluation perceptuelle de la qualité d'image

Plus de 100 métriques d'évaluation de la qualité ont été proposées dans la littérature (Pedersen and Hardeberg, 2009). Cependant, dans cette section, seule une partie des mesures les plus importantes est présentée et qui est également utilisée dans cette thèse.

Mesures traditionnelles de la qualité d'images

Les approches traditionnelles d'évaluation perceptuelle de la qualité d'image sont basées sur la mesure des erreurs (différences de signal) entre les images dégradées et les images de référence. Ces erreurs sont quantifiées de manière à simuler la sensibilité visuelles humaines. Dans ce qui suit, nous allons résumer les principales mesures traditionnelles.

1. Métriques mathématiques basées sur les pixels : L'erreur quadratique moyenne (MSE) et le rapport signal/bruit en crête (PSNR) sont les mesures populaires de différence en traitement d'images et de vidéos. Ils s'expriment comme suit :

$$MSE = \frac{1}{m_g \times n_g} \sum_m \sum_n (\mathbf{f} - \hat{\mathbf{f}})^2 \quad (1.15)$$

$$PSNR = 10 \times \log \frac{255^2}{MSE} \quad [dB] \quad (1.16)$$

2. Modèle de Mannos et Sakrison ([Mannos and Sakrison, 1974](#)). Cette métrique est basée sur la normalisation de toutes les valeurs de luminance et mesure une similarité en amplitudes des transformées de Fourier entre les images,
3. Modèle de Gervais : Ce modèle est utilisé afin d'étudier la confusion entre les lettres de l'alphabet ([Gervais et al., 1984](#); [Rushmeier et al., 1995](#)),
4. Prédicteur de différences visibles ([Daly, 1993](#)) : c'est l'une des métriques les plus connues pour mesurer la distorsion des images,
5. Mesure de distorsion perceptive de Teo et Heeger ([Teo and Heeger, 1994](#)) : Cette mesure est basée sur la normalisation d'un modèle non linéaire. Ce modèle comprend l'effet de la phase ainsi que de l'amplitude dans la représentation spatio-temporelle de l'image,
6. Modèle de discrimination visuelle ([Lubin, 1995](#)),
7. Modèle HVS basé sur la pyramide de Gabor ([Taylor et al., 1997](#)),
8. Différence stochastique d'image couleur de Neumann et al [Neumann et al. \(1998\)](#),
9. Prédicteur de différence visuelle par ondelettes ([Bradley, 1999](#)),
10. Modèle à plusieurs niveaux d'évaluation de la qualité ([Oh et al., 2001](#)).

Mesures de la qualité d'images basée sur la similarité structurelle

Contrairement à l'approche traditionnelle basée sur la sensibilité aux erreurs, l'évaluation de la qualité de l'image basée sur la similarité structurelle a été proposée dans (Wang et al., 2002, 2004). Cette approche de la similarité structurelle repose sur la philosophie selon laquelle la fonction principale d'un système visuel humain est d'extraire l'information structurelle provenant du champ de vision, et que le système HSV est très adapté à cet effet. Par conséquent, une mesure de la perte d'information structurelle peut fournir une bonne approximation de la distorsion perçue d'une image.

1. Indice de similarité structurelle (Wang et al., 2004) : c'est un exemple spécifique d'une mesure de qualité de similarité structurelle que nous détaillons par la suite.
2. Mesure de qualité d'image en niveaux de gris basée sur la décomposition SVD (Shnayderman et al., 2004, 2006) : cette métrique simple est capable de mesurer la distorsion pour les différents types et différents niveaux de distorsion. Tout d'abord, la décomposition SVD est appliquée sur des blocs (de taille $m_b \times n_b$), afin de calculer l'erreur locale D_j exprimée comme suit :

$$D_j = \sqrt{\sum (s_i - \hat{s}_i)^2} \quad (1.17)$$

où s_i et \hat{s}_i sont les valeurs singulières du bloc de l'image originale et celui de l'image dégradée.

Ainsi, la mesure globale de distorsion est donnée, pour l'image complète, par :

$$MSVD = \frac{\sum_{j=1}^M |D_j - D_{med}|}{M} \quad (1.18)$$

où D_{med} représente la médiane de la séquence D_j . $M = (m_g/m_b) \times (n_g/n_b)$ est le nombre d'échantillons dans la carte de distorsion.

3. Similarité structurelle basée sur le gradient (Chen et al., 2006) : c'est une version améliorée de l'indice SSIM. Elle est basée sur l'utilisation des opérateurs de gradient pour calculer les différences en contraste et en structure.

D'autre part, vu le nombre très important et la diversité des modèles et techniques d'évaluation de la qualité d'image, plusieurs études de comparaison des performances de

ces métriques ont été publiées dans la littérature (Hore and Ziou, 2010; Sheikh et al., 2006; Seshadrinathan et al., 2010). Pour notre travail la métrique retenue est l'indice SSIM qui a été introduit dans (Wang et al., 2004). Ce choix est justifié par le fait que cette métrique est plus efficace lorsqu'elle est utilisée à l'échelle appropriée. Par ailleurs, elle est plus précise, plus cohérente que les mesures classiques MSE et PSNR, simple à mettre en œuvre et peut être considérée comme une fonction différentiable.

Dans la section suivante, nous allons introduire et décrire les différentes techniques classiques et récentes de séparation de sources à partir des mélanges d'images observées.

1.5 Séparation aveugle de sources images

La séparation de source (BSS : Blind Source Separation) désigne un ensemble d'approches dont l'objectif est d'extraire un ensemble de sources images à partir d'un certain nombre d'observations (mélange d'images) sans connaissance *a priori* sur les coefficients du mélange. L'outil d'analyse en composantes indépendantes (ICA) est fréquemment utilisé pour désigner les techniques de séparation BSS qui sont strictement basées sur l'indépendance statistique des sources. Ainsi, les techniques ICA essaient généralement de minimiser la dépendance statistique des signaux restaurés (Farid and Adelson, 1999; Hyvärinen and Oja, 2000; Naik and Kumar, 2011).

En particulier, dans les applications de séparation d'images, plusieurs approches bayésiennes ont été proposées (Kayabol et al., 2009; Tonazzini et al., 2006). Par exemple, dans (Kayabol et al., 2009) les auteurs adoptent un modèle de champ aléatoire de Markov (MRF) pour préserver la dépendance spatiale des pixels voisins sur un modèle 2D.

Dans ce qui suit, un aperçu sur les différentes techniques existantes de séparation aveugle de sources images est brièvement présenté.

1.5.1 Techniques classiques de décomposition

Dans un contexte multi-canal, les techniques BSS ont tendance à produire des décompositions plus fiables et significatives de sources images que les méthodes classiques de

décomposition, telles que PCA (Principal Component Analysis) et FA (Factor Analysis) (Hyvärinen et al., 2004; Lathauwer, 2011). Ceci est dû au principe de l'indépendance (ou de la décorrélation).

Néanmoins, ces dernières techniques sont couramment utilisées comme étape de pré-traitement avant les actuels algorithmes BSS. De plus, certaines idées et techniques sont partagées à la fois par PCA, FA et par les méthodes BSS (Cichocki and Amari, 2002). Par conséquent, les méthodes classiques de PCA et FA sont brièvement présentées dans cette section.

Méthode d'analyse en composantes principales (PCA)

PCA est l'une des techniques les plus anciennes et les plus connues pour l'analyse de données et les statistiques multivariées (Cichocki and Amari, 2002). Son objectif est de décorréler les variables statistiquement liées. Cela signifie que la PCA dérive un nombre relativement petit de combinaisons linéaires décorrélées (composantes principales) tout en conservant une valeur maximale de la variance des données. Autrement dit, les approches PCA tentent de réduire la redondance des données. Habituellement, les composantes principales avec la plus grande variance sont supposés avoir des informations importantes sur les sources, tandis que celles ayant la plus petite variance ont tendance à être associées au bruit (Cichocki and Amari, 2002).

Mathématiquement, la PCA est basée essentiellement sur la structure de la matrice de covariance des données et ceci par le biais de ses vecteurs et valeurs propres. Ainsi, le défi principal dans les méthodes PCA est la sélection du nombre de composantes principales à retenir. Par ailleurs, les technique PCA sont utilisées souvent dans différents domaines : décomposition des données, classification, filtrage et le blanchiment, ce qui constitue une étape de pré-traitement fréquemment sollicitée dans le cadre de la BSS (Plumbley and Oja, 2004).

Méthode d'analyse factorielle (FA)

Bien que la PCA ne suppose aucun modèle statistique particulier pour les données, ce dernier peut également être dérivé du modèle générateur latent de FA (Hyvärinen et al., 2004), donné comme suit :

$$\mathbf{g} = \mathbf{H} \mathbf{f} + \mathbf{w} \quad (1.19)$$

où \mathbf{H} représente la matrice de mélange, \mathbf{f} le vecteur des différentes sources (gaussien centré $E[\mathbf{f} \cdot \mathbf{f}^T] = I$) et \mathbf{w} est un bruit blanc gaussien centré.

Tenant compte de ce modèle, si \mathbf{f} est gaussien, alors il en est de même pour \mathbf{g} . Dans ce cas, la fonction de vraisemblance peut être formulée et les lignes de la matrice \mathbf{H} peuvent être estimées par maximum de vraisemblance lorsque la puissance du bruit tend vers zéro.

L'objectif des techniques FA est généralement différent de celui de la PCA. Au lieu de réduire la redondance des données, les méthodes FA tentent généralement de trouver des facteurs (pertinents et significatifs) susceptibles d'expliquer les observations \mathbf{g} en utilisant le modèle précédent (1.19). Dans FA, les éléments de \mathbf{H} sont les charges factorielles tandis que \mathbf{w} est généralement interprété comme un vecteur de facteurs spécifiques au lieu du bruit.

1.5.2 Méthodes statistiques du second ordre pour la BSS

Différentes approches existent dans la littérature afin de réaliser la BSS. Certaines méthodes sont basées sur les statistiques d'ordre supérieur (HOS : Higher Order Statistics) des sources (De Lathauwer et al., 1996). D'autres considèrent la structure temporelle (spectrale) des signaux et sont connues sous le nom de techniques basées sur les statistiques du second ordre (SOS : Second Order Statistics) (Abed-Meraim et al., 2001). L'hypothèse selon laquelle les composantes sont indépendantes implique qu'elles n'ont pas de corrélations spatio-temporelles ou spatio-fréquentielle.

En fait, ces approches ont une conception simple, elles ont été initialement proposées dans (Tong et al., 1991) par l'élaboration de l'algorithme AMUSE (Algorithm for Multiple Unknown Signals Extraction). Par la suite, cette méthodologie a été étendue avec plusieurs

décalages temporels, à l'aide des techniques itératives comme l'algorithme SOBI (Second Order Blind Identification) introduit par (Belouchrani et al., 1997; Ziehe and Müller, 1998).

Algorithme AMUSE

Cette technique très simple qui suppose que les sources ont une structure temporelle avec différentes fonctions de corrélation (à deux décalages temporels) cherche à séparer un mélange en forçant la décorrélation au second ordre des sources (ayant une corrélation croisée nulle) (Cichocki and Amari, 2002)..

Le fonctionnement de l'algorithme AMUSE se résume en deux étapes, un blanchiment des données suivi d'une décomposition en valeur singulière, sa complexité est faible. Cependant, cette méthode nécessite que les vecteurs propres de la matrice de covariance soient définis de manière unique, ce qui restreint l'applicabilité de cette méthode (Tong et al., 1990). Toutefois, AMUSE n'est pas très robuste, car il utilise seulement deux décalages temporels. Une solution plus stable est fournie par l'algorithme SOBI.

Algorithme SOBI

C'est une extension de la technique AMUSE qui sert à améliorer la qualité de séparation des images en prenant en compte plus de deux décalages temporels. Pour estimer les composantes, il suffit que les covariances des composantes pour un de ces décalages temporels soient différentes. Néanmoins, la diagonalisation simultanée des matrices de covariance correspondantes ne peut être calculée exactement (Belouchrani et al., 1997). Par conséquent, l'estimation de la matrice de séparation \mathbf{B} est essentiellement basée sur le fait que les matrices de covariance estimées soient diagonales, le plus possible. Ceci est approximativement atteint par une diagonalisation conjointe.

Ceci implique que les sources soient estimées par minimisation de la somme des éléments non-diagonaux de plusieurs matrices de covariances calculées avec les différents retards. Cette opération nécessite aussi une étape de blanchiment. Dans notre travail, nous nous intéressons à une version améliorée de l'algorithme SOBI, qui est l'algorithme

pondéré WASOBI (Yeredor, 2000).

A noter que, si les composantes ont des auto-covariances identiques (c'est-à-dire des spectres de puissance identique), elles ne peuvent être estimées par AMUSE ou SOBI. Ceci conduit à l'utilisation des méthodes HOS, qui permettent d'avoir des spectres de puissance identiques pour les composantes ou même avoir des distributions égales tant que les composantes ne sont pas gaussiennes (Hyvärinen and Oja, 2000).

1.5.3 Méthodes des statistiques d'ordre supérieur pour la BSS

L'analyse en composantes indépendantes est la technique la plus connue comme méthode HOS. L'objectif de ces approches est de séparer les sources indépendantes, en ne considérant que les observations et en supposant qu'elles sont linéairement mélangées. Sans aucune structure temporelle, ces approches réduisent les dépendances statistiques d'ordre supérieur en essayant de rendre les sources aussi indépendantes que possible.

Ces techniques évaluent l'indépendance des composantes estimées en s'appuyant sur des statistiques telles que le kurtosis et la négentropie.

1. Le kurtosis, $kurt(\cdot)$, est le cumulante de quatrième ordre d'une variable aléatoire X , calculé comme suit :

$$kurt(X) = E[X^4] - 3 (E[X^2])^2 \quad (1.20)$$

2. La négentropie dans une statistique est basée sur le concept d'entropie différentielle. La négentropie, $J(X)$, est nulle seulement pour une variable gaussienne et elle est toujours positive. Elle est définie comme (Comon, 1994; Hyvärinen et al., 2004) :

$$J(X) = H(X_{gauss}) - H(X) \quad (1.21)$$

où $H(\cdot)$ représente l'entropie de la variable aléatoire et X_{gauss} est un vecteur aléatoire gaussien qui a la même matrice de covariance que X .

A noter que cette méthode est extrêmement populaire dans le domaine de la séparation d'images. Parmi les algorithmes BSS les plus utilisés, on trouve FastICA, InfoMax et JADE (Chichocki, 2015; Barhate, 2013; Goel et al., 2015; Langlois et al., 2010).

Algorithme FastICA

L'algorithme FastICA (Koldovsky et al., 2006) tente de séparer les mélanges sur la base de leur non gaussianité (Hyvärinen et al., 2004). Il s'agit d'un algorithme rapide itératif à point fixe qui cherche des projections qui maximisent la non-gaussianité des composantes à l'aide de leur kurtosis (Bingham and Hyvärinen, 2000).

La fonction de coût la plus simple pour un algorithme basé sur le kurtosis, $\mathcal{J}(W)$, est définie par (Sanei and Chambers, 2013) :

$$\mathcal{J}(W) = -\frac{1}{4}|kurt(\mathbf{Y})| = -\frac{\beta}{4}kurt(\mathbf{Y}) \quad (1.22)$$

où \mathbf{Y} est l'estimée d'une composante, β est le signe du kurtosis. Cette fonction de coût peut être minimisée par une descente de gradient standard.

Dans le même contexte que les méthodes ICA, l'implémentation de nouvelles techniques BSS destinées spécialement pour des mélanges d'images parcimonieuses a connu un énorme essor depuis les années 2000. Cette exploitation de la représentation parcimonieuse des images ou plus généralement des signaux sources a abouti à beaucoup d'améliorations en performances.

Dans notre travail, nous reviendrons sur l'algorithme ISBS proposé dans (Souidene et al., 2007).

Algorithme InfoMax

L'approche de maximisation de l'information (InfoMax) met en œuvre un algorithme de gradient basé sur les réseaux de neurones où la règle d'apprentissage repose sur le principe de maximisation de l'information (Bell and Sejnowski, 1995). L'algorithme InfoMax maximise l'entropie de sortie d'un réseau neuronal dont les sorties sont non linéaires. Ainsi, cette méthode est similaire à la maximisation de la non-gaussianité des sources, proche des méthodes BSS basées sur le maximum de vraisemblance (Pearlmutter and Parra, 1997).

D'autre part, l'algorithme InfoMax dans sa version originale ne peut extraire que les

sources super-gaussiennes. Pour cette raison, il a été amélioré pour inclure un mode ‘étendu’ capable d’estimer des sources sous-gaussiennes (p. ex. les sinusoides) (Lee et al., 1999).

Algorithme JADE

Une autre approche habituelle des méthodes HOS-BSS est l’algorithme JADE proposé dans (Cardoso and Souloumiac, 1996). Comme la matrice de covariance est le tenseur cumulant du second ordre (le tenseur du quatrième ordre est défini par les cumulants de quatrième ordre), ces derniers sont considérés comme une mesure de non-gaussianité, qui est utilisée pour définir l’indépendance entre les sources.

Après avoir décorrélé les variables à l’aide d’une décomposition en valeurs propres du tenseur cumulant du second ordre, l’algorithme JADE cherche une rotation orthogonale qui sert à rendre les mélanges observés indépendants au quatrième ordre et ceci afin d’estimer les sources (Hyvärinen et al., 2004). L’inconvénient de cette technique est le temps de calcul important pour les problèmes avec une dimension élevée.

1.6 Conclusion

Dans ce chapitre, nous avons présenté un ensemble de techniques (classiques et actuelles) et des algorithmes existants en traitement d’images. L’étude menée se décline principalement en quatre axes complémentaires : l’identification aveugle d’un système en estimant ses filtres dégradants, la restauration d’images dans un contexte multi-canal, l’évaluation de la qualité d’images et finalement la séparation aveugle d’images linéairement mélangées.

Chapitre 2

Identification aveugle des systèmes

Sommaire

2.1	Introduction	34
2.2	Formulation du problème	35
2.3	Méthodes proposées pour l'identification aveugle des filtres	38
2.3.1	Méthode des relations croisées CR	38
2.3.2	Méthode des relations croisées symétrique SCR	41
2.3.3	Méthode SCR robuste (R-SCR)	42
2.4	Résultats et discussion	45
2.4.1	Étude des performances des méthodes proposées d'identification du canal (SCR et R-SCR)	45
2.4.2	Évaluation des performances d'identification du canal pour la restauration d'images (deblurring)	47
2.5	Conclusion	48

2.1 Introduction

L'identification aveugle du système (BSI : Blind System Identification) est une technique fondamentale souvent utilisée en traitement de signal qui vise à récupérer les informations inconnues d'un système uniquement à partir de ses sorties. Cette technique est particulièrement adaptée aux applications où toutes les données disponibles (les observations) sont générées à partir d'un système à entrée unique et sorties multiples (SIMO : Single-Input Multiple-Outputs). Ce système inconnu est piloté par une entrée inconnue. Le mot 'aveugle' signifie simplement que l'entrée du système et ses caractéristiques (sa fonction de transfert) ne sont pas disponibles durant le processus d'identification. La tâche de cette technique d'identification (voir figure 2.1) est d'estimer l'entrée f et/ou la fonction du système H à partir de la sortie g . Il convient de noter que si la fonction du système ou son entrée est connue, le problème devient plus standard et plus simple.

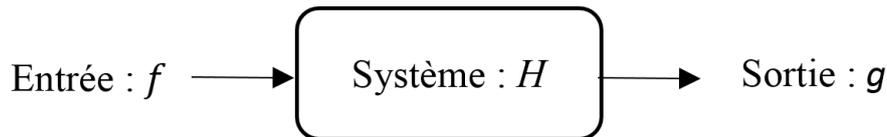


FIGURE 2.1 – Un système avec une entrée inconnue et une fonction de système inconnue.

Depuis les années 80, l'identification aveugle des systèmes connaît un intérêt croissant dans différents domaines : communication des données numériques, reconnaissance vocale, traitement des signaux sismiques et surtout le traitement d'images : astronomie, télédétection et imagerie médicale (Abed-Meraim et al., 1997c) pour lesquelles plusieurs méthodes ont été proposées dans la littérature (Souidene et al., 2009; Harikumar and Bresler, 1999a; Giannakis and Heath, 2000). Dans cette partie de travail, et comme une première contribution, nous proposons une nouvelle méthode d'identification aveugle, nommée 'méthode des relations croisées symétrique (SCR : Symmetric Cross Relation)', qui est une version simplifiée (i.e., de coût de calcul réduit) de la méthode des relations croisées (CR : Cross Relation) classique introduite dans (Liu et al., 1994).

Récemment, la propriété de parcimonie a connue un essor dans de nombreux travaux incluant la restauration d'image. Dans (Zhang and Zhang, 2009), la parcimonie des images est exploitée dans un modèle non-aveugle de déconvolution en utilisant une méthode

itérative des moindres carrés pondérés, généralisée plus tard par l'utilisation d'un modèle de régression. Ensuite, une méthode d'estimation aveugle de flou a été proposée en utilisant la parcimonie des images naturelles tirant profit des curvelets (Cai et al., 2009).

Dans cette section, notre contribution s'inscrit dans le cadre de l'identification aveugle d'un système (filtres dégradants) qui n'est qu'une étape dans le processus de restauration. En effet, ces fonctions de flous identifiées vont être exploitées pour permettre l'estimation de l'image originale qui va être traitée dans le chapitre suivant (Chapitre 3). Nous proposons d'exploiter la propriété de parcimonie pour rendre robuste la méthode SCR dans le cas où l'ordre du canal est surestimé. Ainsi, notre seconde contribution est une version de la méthode SCR, robuste aux erreurs de surestimation de l'ordre du canal. Les performances de cette méthode désignée par R-SCR (Robust Symmetric Cross Relation) sont évaluées ensuite à l'aide de simulations numériques.

2.2 Formulation du problème

Comme pour le problème de la restauration d'images, l'identification des filtres dégradants est un problème mal-posé, ce qui exige et rend nécessaire de tirer profit de la diversité offerte par le multi-canal. Dans cette section, nous considérons un système SIMO avec plusieurs sorties dégradées de la même scène. Dans le domaine spatial, un tel système peut être modélisé pour chaque pixel (m, n) , $m = 1, \dots, m_g$ et $n = 1, \dots, n_g$, par :

$$\begin{aligned} g_i(m, n) &= h_i(m, n) \star f(m, n) + w_i(m, n) \\ &= \sum_{l_1=0}^{m_h-1} \sum_{l_2=0}^{n_h-1} h_i(l_1, l_2) f(m - l_1, n - l_2) + w_i(m, n) \end{aligned} \quad (2.1)$$

où (\star) désigne le produit de convolution linéaire, \mathbf{f} indique l'image originale $(m_f \times n_f)$ et \mathbf{g}_i , \mathbf{w}_i , \mathbf{h}_i désignent les images observées $(m_g \times n_g)$, le bruit additif pour chaque canal $(m_g \times n_g)$ et les (PSF)¹ fonctions d'étalement d'un point $(m_h \times n_h)$, respectivement, pour $i = 1, \dots, K$. Les $K > 2$ filtres causaux inconnus \mathbf{h}_i sont supposés assez différents afin de satisfaire la condition de diversité (Giannakis and Heath, 2000).

1. PSF est l'abréviation de 'Point Spread Function' pour laquelle une notation causale est adoptée pour simplifier l'écriture. Aussi, la taille du canal, (m_h, n_h) correspond à la taille maximale des PSFs.

Dans ce travail d'identification des fonctions de flou dans le contexte de la restauration d'images, les filtres dégradants h_i que nous cherchons à estimer sont de natures diverses où plusieurs types de dégradations existent ('flou de bouger', 'flou moyenneur', 'flou Gaussien' et 'flou type disque'). Les réponses fréquentielles de ces dégradations sont présentées dans la figure 2.2 et des images dégradées (floutées) par ces filtres sont montrées dans la figure 2.3.

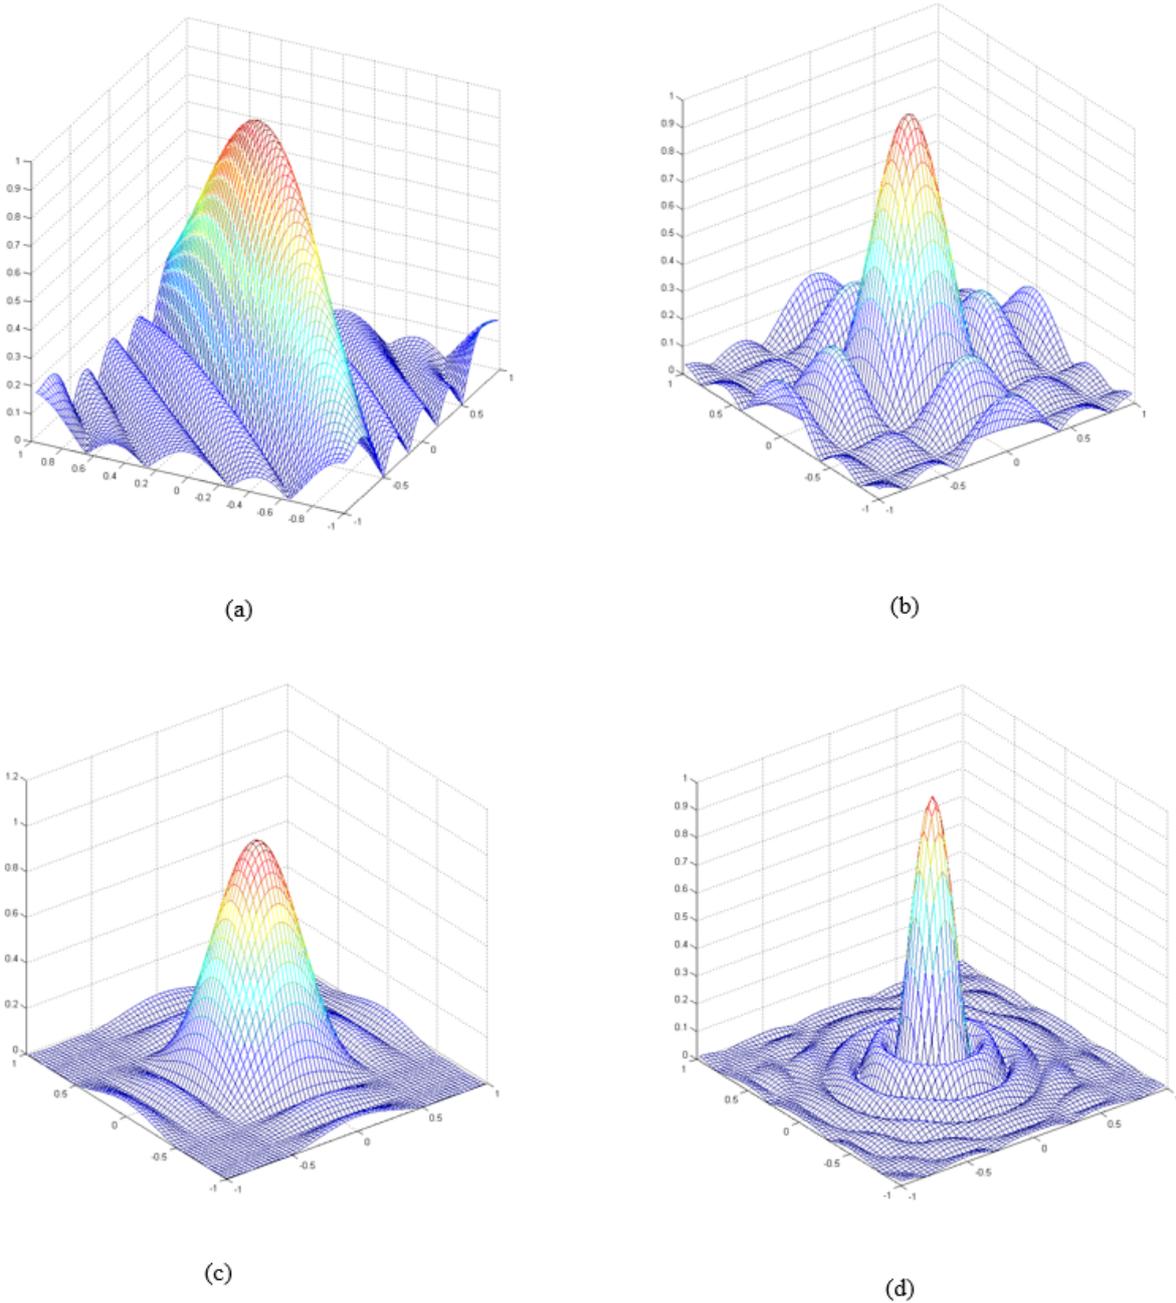


FIGURE 2.2 – Réponses fréquentielles des différents filtres dégradants utilisés, (a) Flou de bouger de 7 pixels dans la direction 40 degrés, (b) Flou moyenneur de taille (5×5) , (c) Flou Gaussien de taille (5×5) et de variance 1.5 et (d) Flou de type disque de rayon 5.

2.2. FORMULATION DU PROBLÈME



FIGURE 2.3 – Les $K = 4$ images dégradées par les différents filtres présentés précédemment à la figure 2.2.

Dans un contexte multi-canal et afin de pouvoir restaurer l'image originale, nous proposons dans un premier temps d'identifier en aveugle (i.e. en utilisant seulement les images dégradées) les fonctions PSFs. Plusieurs solutions existent dans la littérature incluant la méthode des relations croisées (CR) (Souidene et al., 2005) qui sera brièvement rappelée dans la section suivante. Tout d'abord, nous introduisons une simplification de cette méthode permettant de réduire son coût de calcul moyennant une certaine condition de diversité des filtres. Ensuite, nous considérons le problème difficile où il s'agit d'identifier en aveugle les canaux sans connaissance à priori de leur taille exacte.

Cette problématique a été abordée dans la littérature de deux manières différentes : en introduisant des méthodes d'identification robustes à une surestimation de l'ordre (taille)

du canal, e.g. (Gazzah et al., 2002), ou en proposant des améliorations sur les techniques d'estimation de l'ordre, e.g. (Via et al., 2006). Et ce afin d'éviter autant que possible le problème de surestimation de l'ordre en question. Les travaux de cette thèse s'inscrivent dans la première démarche avec ajout d'une contrainte de parcimonie (sous la forme d'un terme de pénalisation ℓ_1) aux critères aveugles existants afin de les rendre robuste aux erreurs de l'ordre du canal. Dans ce qui suit, nous motivons le choix de cette contrainte et étudions ensuite ses performances via des simulations numériques.

2.3 Méthodes proposées pour l'identification aveugle des filtres

Plusieurs méthodes ont été proposées dans la littérature pour résoudre le problème d'identification des fonctions de flou, particulièrement celles qui s'inscrivent dans un contexte aveugle multi-canal. Nous citons, à titre d'exemple, la méthode des sous-espaces (SS : Sub-Space method) qui a été introduite pour la restauration d'images dans les travaux de (Wirawan et al., 2003). Cette méthode est basée sur la projection des observations sur un ensemble de sous espaces choisis adéquatement ('*sous espace image*' et '*sous espace bruit*'). Nous trouvons aussi sa version simplifiée qui est la méthode du sous-espace bruit minimal (MNS : Minimum Noise Subspace method) proposée par (Hua et al., 1997). Ces méthodes reposent principalement sur la structure de la matrice de filtrage et la relation entre cette dernière et les images observées. Néanmoins, pour notre travail nous avons opté pour la méthode des relations croisées qui se base sur la commutativité du produit de convolution.

2.3.1 Méthode des relations croisées CR

Dans cette section, la méthode des relations croisées (CR) introduite par (Liu et al., 1994; Harikumar and Bresler, 1999b) a été retenue pour sa simplicité (comparée aux autres méthodes de sous-espace SS et MNS). En effet, dans le cas non bruité, il est possible d'exprimer pour chaque pixel (m, n) , grâce à la commutativité de la convolution,

la relation croisée suivante :

$$h_i \star h_j \star f(m, n) = h_j \star h_i \star f(m, n) \quad (2.2)$$

avec

$$g_i(m, n) = h_i \star f(m, n), \quad g_j(m, n) = h_j \star f(m, n)$$

Par conséquent

$$h_i \star g_j(m, n) = h_j \star g_i(m, n)$$

Ce qui peut être écrit sous la forme matricielle suivante :

$$[g_i(m, n)^T - g_j(m, n)^T] \begin{bmatrix} h_j \\ h_i \end{bmatrix} = 0 \quad \forall(i, j), \quad \forall(m, n) \quad (2.3)$$

avec $\mathbf{h}_1, \dots, \mathbf{h}_K$, les versions vectorisées (colonne par colonne) de toutes les PSFs h_1, \dots, h_K .

La relation précédente est valide pour chaque paire d'images observée (i, j) . Avec K canaux indépendants et en l'écrivant pour toutes les paires possibles, ceci nous offre un total de $K(K - 1)/2$ équations (voir figure 2.4).

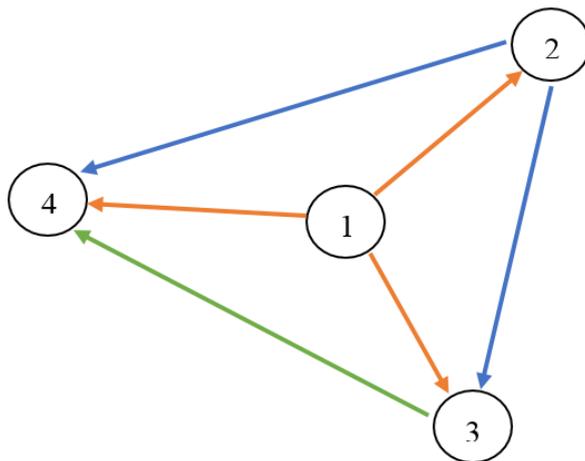


FIGURE 2.4 – Les $K(K - 1)/2$ paires possibles pour l'algorithme CR. Exemple pour $K = 4$.

Ces équations peuvent être exprimées comme suit :

$$\Psi(m, n) \mathbf{h} = 0 \quad \forall(m, n) \quad (2.4)$$

où $\mathbf{h} = [\mathbf{h}_1^T, \dots, \mathbf{h}_K^T]^T$ est le vecteur global de toutes les PSFs. Ψ est la matrice définie pour chaque pixel (m, n) par :

$$\Psi(m, n) = \begin{bmatrix} \Psi_1(m, n) \\ \vdots \\ \Psi_{K-1}(m, n) \end{bmatrix}$$

avec $k = 1, \dots, K - 1$, et :

$$\Psi_k(m, n) = \begin{bmatrix} 0 & \cdots & 0 & \mathbf{g}_{k+1}^T & -\mathbf{g}_k^T & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \\ 0 & \cdots & 0 & \mathbf{g}_K^T & 0 & -\mathbf{g}_k^T \end{bmatrix}$$

Il s'avère que, moyennant la connaissance de la taille exacte du canal (i.e. m_h et n_h), l'équation (2.5) caractérise de manière unique (à un facteur scalaire près) le vecteur PSF \mathbf{h} . Ainsi, la méthode CR consiste à résoudre l'équation (2.5) conformément à une minimisation au sens des moindres carrés, comme suit :

$$\begin{aligned} \hat{\mathbf{h}} &= \arg \min_{\mathbf{h}} \sum_{m,n} \|\Psi(m, n) \mathbf{h}\|_2^2 \\ &= \arg \min_{\mathbf{h}} \sum_{m,n} (\Psi(m, n) \mathbf{h})^T (\Psi(m, n) \mathbf{h}) \\ &= \arg \min_{\mathbf{h}} \sum_{m,n} \mathbf{h}^T \Psi(m, n)^T \Psi(m, n) \mathbf{h} \\ &= \arg \min_{\mathbf{h}} \mathbf{h}^T \mathbf{Q} \mathbf{h} \end{aligned} \quad (2.5)$$

où \mathbf{Q} désigne la matrice de la forme quadratique du critère CR, exprimée par :

$$\mathbf{Q} = \sum_{m,n} \Psi(m, n)^T \Psi(m, n)$$

Pour éviter la solution triviale $\mathbf{h} = 0$, la contrainte $\|\mathbf{h}\| = 1$ ou autrement $h_{i_0} = 1$ pour

un élément i_0 choisi est utilisée. Dans la section qui suit, nous introduisons une version améliorée de la méthode CR.

2.3.2 Méthode des relations croisées symétrique SCR

Notre première contribution dans ce travail d'identification consiste à réduire le nombre $K(K-1)/2$ des relations croisées nécessaires pour l'algorithme SCR. Ainsi, seulement K relations sont utilisées de manière 'symétrique' comme le montre la figure 2.5 et ceci afin de réduire le coût de la méthode CR. Plus précisément, les K paires utilisées sont les suivantes :

$$p_1 = (1, 2), \quad p_2 = (2, 3), \quad \dots, \quad p_{K-1} = (K-1, K), \quad p_K = (K, 1)$$

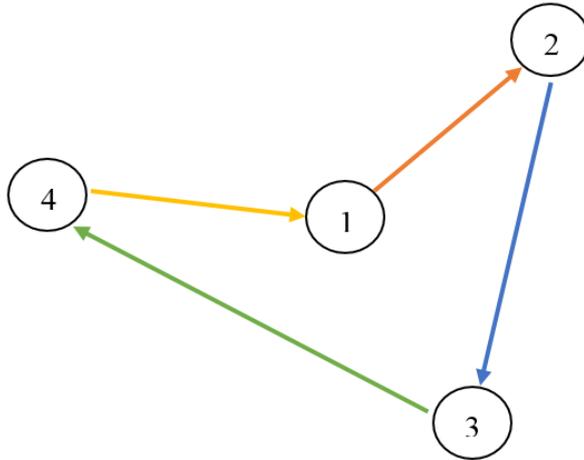


FIGURE 2.5 – Les K paires possibles pour l'algorithme SCR, construites pour $K = 4$ images observées.

Les K paires sont choisies de manière à assurer une certaine symétrie dans l'utilisation des sorties du système (chacune participe à 2 relations croisées), mais aussi de façon à garantir l'identifiabilité du système comme le stipule le lemme suivant :

Lemme : *Dans le cas non bruité, si les canaux vérifient la condition :*

$$H_i(z_1, z_2) = \sum_{l_1, l_2} h_i(l_1, l_2) z_1^{-l_1} z_2^{-l_2}$$

soient deux à deux premiers entre eux, l'ensemble des K relations croisées précédentes permet l'identification unique (à une constante près) du vecteur canal \mathbf{h} .

La démonstration de ce lemme (non fournie ici) s'inspire de celle de la méthode MNS (Minimum Noise Subspace) dans (Abed-Meraim et al., 1997c) qui permet de montrer qu'un minimum de $K - 1$ relations croisées est requis pour l'identifiabilité des canaux. Pour assurer une symétrie dans le choix de ces relations croisées, nous avons opté pour utiliser K (au lieu de $K - 1$) paires selon la sélection indiquée ci-dessus. Par conséquent, la méthode SCR proposée permet de réduire par un facteur $(K - 1)/2$ la complexité du calcul de la forme quadratique \mathbf{Q} (i.e. le coût est réduit de $O(m_f n_f m_h n_h K(K - 1)/2)$ à $O(m_f n_f m_h n_h K)$).

Un autre avantage de la symétrie est qu'elle permet d'avoir un terme de bruit proportionnel à la matrice identité dans le calcul de la forme quadratique du critère d'identification. Par conséquent, dans ce cas de figure, l'estimation du canal n'est pas affectée asymptotiquement par le terme additif du bruit dans ce cas de figure. Dans la section suivante, nous présentons comme rendre la méthode SCR robuste.

2.3.3 Méthode SCR robuste (R-SCR)

Afin de rendre robuste la méthode SCR proposée, lorsque l'ordre (taille) est mal évalué, nous nous appuyons sur les deux observations suivantes :

- La surestimation de l'ordre du canal conduit à la recherche d'un canal exact parcimonieux comme l'illustre la figure 2.6.
- En absence du bruit (ou asymptotiquement), la méthode SCR permet d'identifier le canal exact à un filtre scalaire près (Harikumar and Bresler, 1999b; Abed-Meraim et al., 1997a), lorsque celui-ci est d'ordre surestimé. Plus précisément, le canal estimé par la méthode SCR s'écrit :

$$\mathbf{H}_{est}(z_1, z_2) = c(z_1, z_2)\mathbf{H}(z_1, z_2)$$

où $\mathbf{H}(z_1, z_2) = [\mathbf{H}_1(z_1, z_2), \dots, \mathbf{H}_K(z_1, z_2)]^T$ et $c(z_1, z_2)$ est un filtre scalaire polynomial d'ordre $(\tilde{m}_h - m_h, \tilde{n}_h - n_h)$. $(\tilde{m}_h, \tilde{n}_h)$ étant les ordres supposés du canal

estimé.

Ainsi, la solution désirée est celle correspondant à $c(z_1, z_2) = c$, une constante, auquel cas le canal $\mathbf{H}_{est}(z_1, z_2)$ a la structure parcimonieuse illustrée dans la figure 2.6.

h_{11}	h_{12}	h_{13}	0	0
h_{21}	h_{22}	h_{23}	0	0
h_{31}	h_{32}	h_{33}	0	0
0	0	0	0	0
0	0	0	0	0

FIGURE 2.6 – Parcimonie de la fonction de flou ($m_h = n_h = 3$) avec surestimation de l'ordre ($\tilde{m}_h = \tilde{n}_h = 5$).

Nous proposons de minimiser le critère SCR avec une contrainte de parcimonie introduite sous forme d'un terme de régularisation ℓ_1 . En effet, la méthode d'optimisation des moindres carrés l_1 -régularisés (Koh et al., 2007) a reçu récemment beaucoup d'intérêt. Avec une normalisation linéaire du vecteur \mathbf{h} sous la forme $\mathbf{h} = [1, \tilde{\mathbf{h}}^T]^T$, le problème d'estimation peut être formulé par un critère des moindres carrés l_1 -régularisé qui peut s'exprimer comme suit :

$$\hat{\mathbf{h}} = \arg \min_{\tilde{\mathbf{h}}} \|\mathbf{A} \tilde{\mathbf{h}} - \mathbf{b}\|_2^2 + \lambda \|\tilde{\mathbf{h}}\|_1 \quad (2.6)$$

où \mathbf{A} et \mathbf{b} sont des sous matrices de la forme quadratique \mathbf{Q} du critère SCR. $\lambda > 0$ est un paramètre de régularisation.

Le choix de la norme l_1 comme une fonction de pénalité (ou terme de régularisation) est approprié pour forcer et promouvoir la parcimonie du vecteur de paramètre $\tilde{\mathbf{h}}$ tout en assurant la convexité de la fonction de coût. La minimisation de cette dernière a été réalisée par l'algorithme itératif LS- l_1 proposé dans (Koh et al., 2007).

La méthode proposée d'identification aveugle des fonctions de flou (R-SCR) peut être résumée dans l'algorithme 1, comme suit :

Algorithme 1 : Identification aveugle des filtres dégradants (PSFs)

1. **Étape A.** *Initialisation* :

- Entrées : K images observées :

$$\mathbf{g} = [\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_K]$$

- Choix du paramètre de régularisation : $\lambda > 0$

2. **Étape B.** *Méthode CR symétrique* :

- Construire pour chaque pixel (m, n) :

$$\Psi(m, n) = \begin{bmatrix} \Psi_1(m, n) \\ \vdots \\ \Psi_K(m, n) \end{bmatrix}$$

- Calculer la forme quadratique :

$$\mathbf{Q} = \sum_{m,n} \Psi(m, n)^T \Psi(m, n)$$

3. **Étape C.** *Pré-traitement* :

- Définir :

$$\mathbf{h} = \begin{bmatrix} 1 \\ \tilde{\mathbf{h}} \end{bmatrix}, \quad \tilde{\mathbf{Q}} = \begin{bmatrix} q_{11} & \mathbf{q} \\ \mathbf{q}^T & \tilde{\mathbf{Q}} \end{bmatrix}$$

- La nouvelle forme quadratique :

$$\mathbf{h}^T \mathbf{Q} \mathbf{h} = \tilde{\mathbf{h}}^T \tilde{\mathbf{Q}} \tilde{\mathbf{h}} + 2 \mathbf{q}^T \tilde{\mathbf{h}} + q_{11}$$

4. **Étape D.** *Estimation des filtres par R-SCR* :

- Donnée : tolérance > 0
- Construire la matrice des données :

$$\tilde{\mathbf{Q}} = \mathbf{L} \mathbf{L}^T, \quad \mathbf{b} = -\mathbf{L}^{-T} \tilde{\mathbf{h}}, \quad \mathbf{A} = \mathbf{L}$$

- Résoudre par l'algorithme itératif LS- ℓ_1 :

$$\hat{\mathbf{h}} = \arg \min_{\tilde{\mathbf{h}}} \|\mathbf{b} - \mathbf{A} \tilde{\mathbf{h}}\|_2^2 + \lambda \|\tilde{\mathbf{h}}\|_1$$

2.4 Résultats et discussion

Plusieurs simulations numériques ont été conduites afin d'évaluer les performances des algorithmes proposés. Soit un système SIMO avec l'image Cameraman (256×256) comme entrée et K sorties. L'image originale est dégradée à l'aide de différents filtres ('fou moyen-neur', 'fou Gaussien' et 'fou type disque') puis par l'ajout d'un bruit blanc gaussien. Les métriques NMSE (Normalized Mean Square Error) et SSIM (Structural SIMilarity index) sont utilisées afin de comparer les performances des méthodes considérées pour différentes valeurs de SNR (Signal to Noise Ratio) suivant un schéma de Monte Carlo.

2.4.1 Étude des performances des méthodes proposées d'identification du canal (SCR et R-SCR)

Dans la première expérience, nous comparons les performances des méthodes CR et SCR en fonction du nombre K de canaux et pour différents niveaux de SNR. La figure 2.7 présente les résultats obtenus et montre qu'avec une légère perte en performance d'estimation, un gain très important en temps de calcul est obtenu (variant de +69% à +77% selon le nombre des observations).

La perte de la qualité d'estimation devient néanmoins importante à faible SNR et grand nombre de canaux (courbes en rouge), scénario dans lequel l'augmentation des relations croisées de K (SCR) à $K(K - 1)/2$ (CR) permet un meilleur lissage de l'effet du bruit.

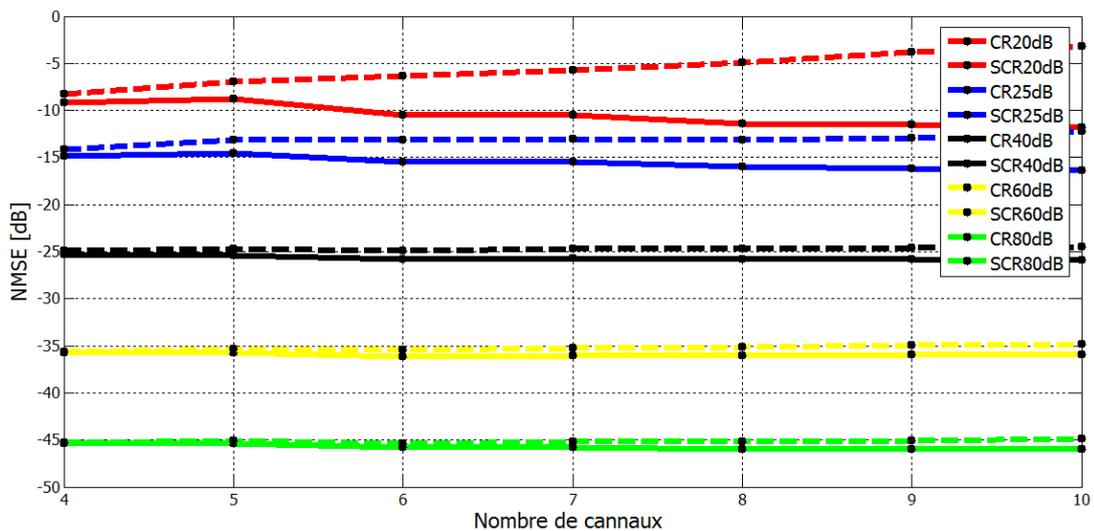


FIGURE 2.7 – NMSE des méthodes CR et SCR en fonction du nombre de canaux.

Dans la seconde expérimentation, nous analysons les performances de la méthode R-SCR en présence d’erreurs de surestimation de l’ordre du canal.

Dans un premier temps, nous illustrons le bon comportement (convergence) de l’algorithme itératif LS- ℓ_1 dans (Koh et al., 2007) que nous avons utilisé pour la minimisation de la fonction coût de l’équation (2.6). Comme le montre la figure 2.8, la convergence de l’algorithme est relativement rapide (quelques dizaines d’itérations) avec une complexité de calcul très raisonnable (voir détails dans (Koh et al., 2007)).

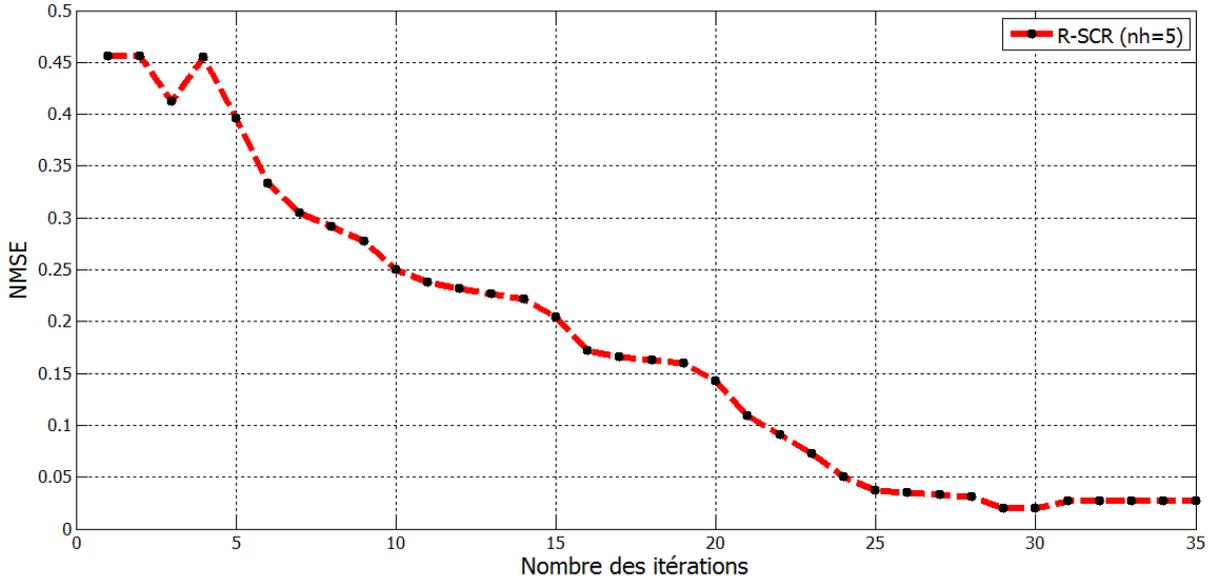


FIGURE 2.8 – Évolution de l’erreur d’estimation des canaux en fonction du nombre d’itérations.

Dans la figure 2.9, nous comparons les performances de la méthode SCR (avec connaissance à priori de l’ordre du canal ($m_h = n_h = 3$)) à celles de la méthode R-SCR pour des ordres surestimés ($\tilde{m}_h = \tilde{n}_h \in \{3, 5, 7\}$). Plus la surestimation de l’ordre est importante, plus la dégradation des performances est élevée. Ceci est confirmé par la simulation de la figure 2.10 qui représente l’évolution du NMSE obtenu en fonction de l’ordre supposé du canal. Cependant, à fort SNR, l’estimation du canal reste ‘correcte’ grâce à l’ajout du terme de pénalisation ℓ_1 que nous avons considéré. Notons que dans le cas où l’ordre est connu, le critère SCR est plus adéquat que celui du R-SCR et conduit à une meilleure estimation du canal, comme le montre les résultats de simulation.

A faible et moyen SNR, les performances de la méthode R-SCR sont fortement dégradées. C’est un point d’amélioration sur lequel nous travaillons pour concilier robustesse à

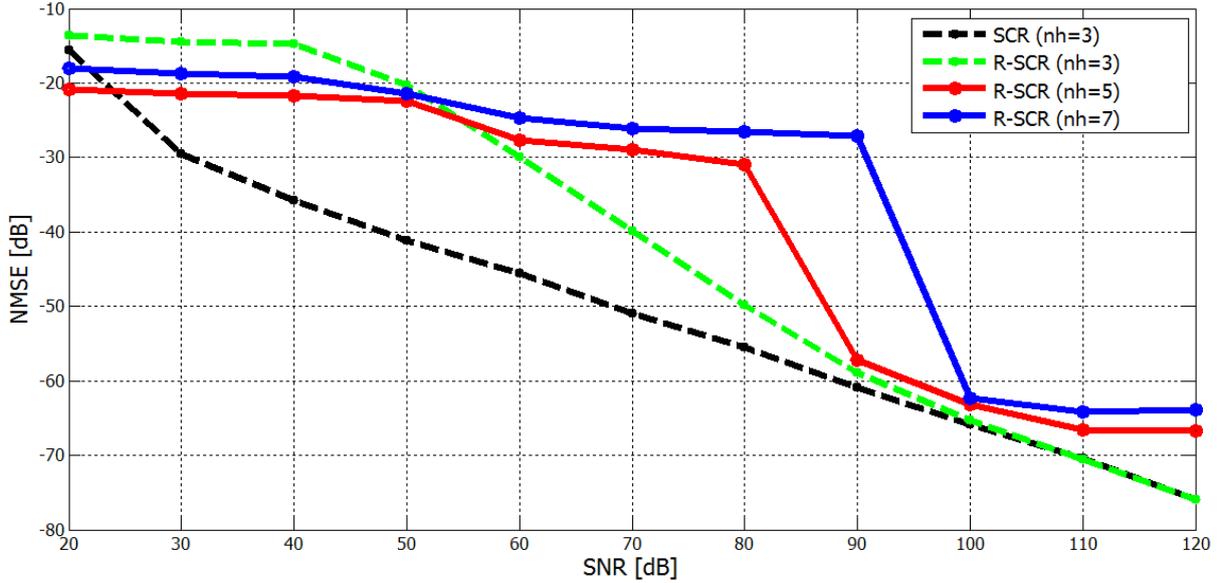


FIGURE 2.9 – Performances de la méthode R-SCR avec surestimation de l'ordre du canal.

la surestimation de l'ordre et aux effets du bruit additif. Un autre point d'amélioration à étudier est celui du choix optimal du coefficient de régularisation λ , que nous avons réalisé de manière *ad-hoc* dans nos simulations.

2.4.2 Évaluation des performances d'identification du canal pour la restauration d'images (deblurring)

Les expérimentations suivantes visent à illustrer les performances de nos méthodes par des simulations de restauration d'images en utilisant l'algorithme Stack développé et proposé dans (Boudjenouia et al., 2016c). L'algorithme stack est détaillé dans le chapitre 3, en exploitant les filtres dégradants présentés auparavant et estimés par les deux méthodes proposées (SCR et R-SCR).

La figure 2.11 illustre le résultat de deblurring en utilisant les filtres dégradants identifiés à la fois par la méthode (CR) et notre méthode (SCR) et ceci en fonction du nombre de canaux $K \in \{4, 8\}$ et pour deux valeurs de $SNR \in \{20, 25\}$ dB.

La figure 2.12 montre la qualité de restauration des images en utilisant les filtres identifiés par la méthode (SCR) et sa version robuste (R-SCR) en fonction de l'ordre surestimé du canal ($\tilde{m}_h = \tilde{n}_h \in \{3, 5, 7\}$).

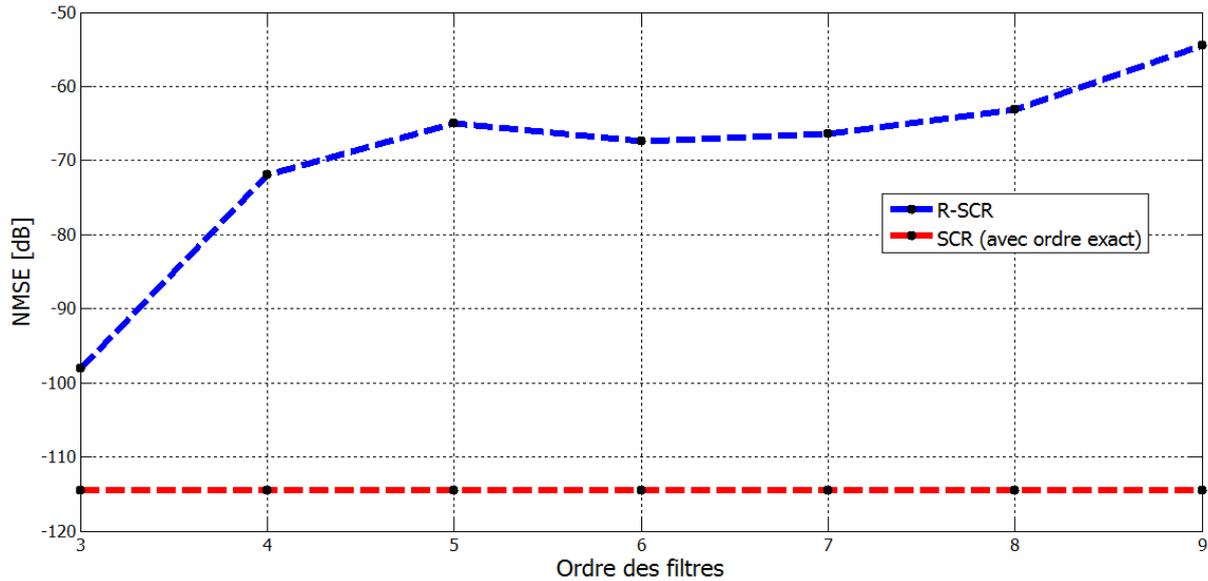


FIGURE 2.10 – Erreur d’identification en fonction de l’ordre de surestimation.

Les résultats de deblurring des figures 2.11 et 2.12 confirment l’étude comparative faite auparavant sur les performances des algorithmes proposés SCR et R-SCR, illustrée par les courbes des figures 2.7 et 2.9, en fonction du nombre de canaux exploités et de l’ordre de surestimation choisi.

2.5 Conclusion

Dans ce chapitre nous avons introduit deux améliorations de la méthode CR (une méthode très populaire en identification aveugle SIMO). Tout d’abord, en réduisant sa complexité numérique (version SCR). Ensuite, en la rendant robuste contre les erreurs de surestimation de l’ordre du canal (version R-SCR). Afin de réduire le coût de calcul, nous avons utilisé un nombre réduit de relations croisées pour lequel nous montrons que l’identifiabilité du canal est garantie sous une certaine condition de diversité des canaux. La robustesse de la méthode est quant à elle réalisée grâce à une contrainte de parcimonie de la solution recherchée. Les simulations réalisées illustrent les potentiels des algorithmes développés. Cependant, il reste une marge importante d’amélioration de la méthode R-SCR afin de mieux concilier sa robustesse aux erreurs de l’ordre du canal et aux effets du bruit additif.

2.5. CONCLUSION

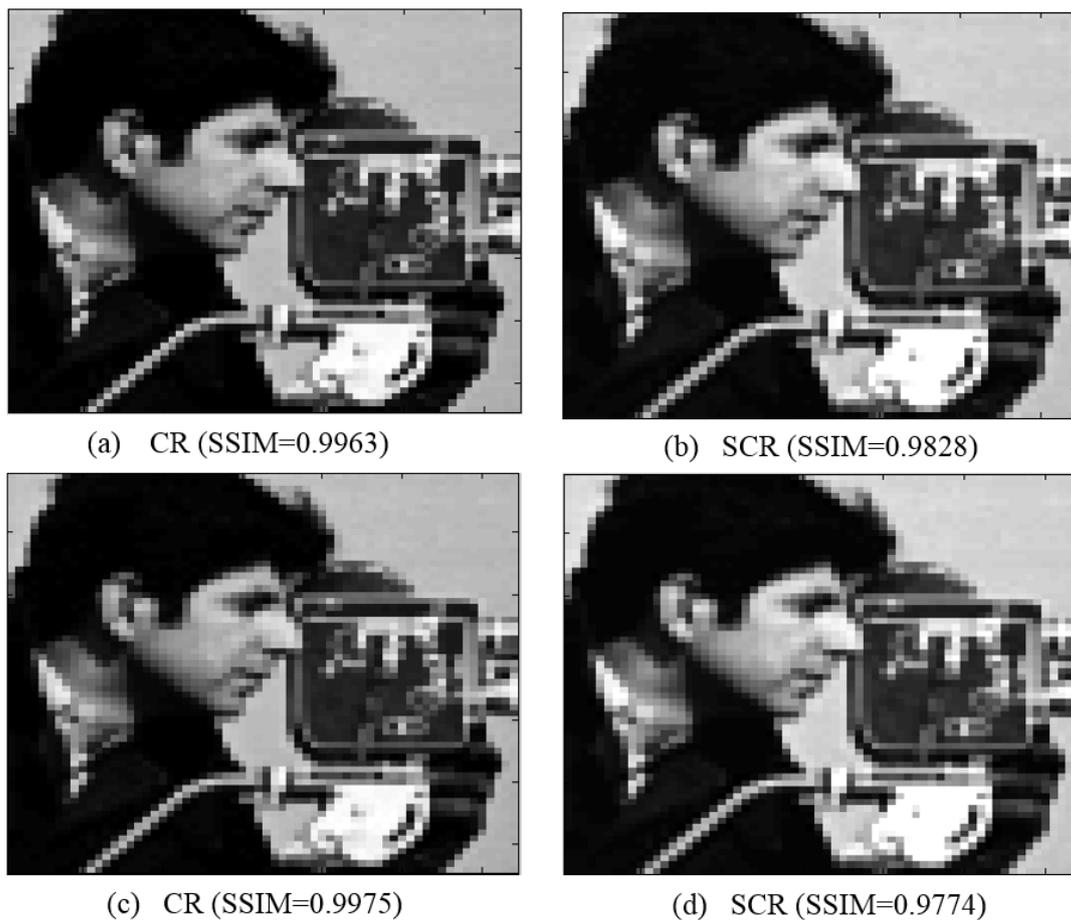


FIGURE 2.11 – Comparaison des performances des méthodes CR et SCR pour la restauration d'images : (a, b) : $K = 4$ et $SNR = 20\text{dB}$, (c, d) : $K = 8$ et $SNR = 25\text{dB}$.

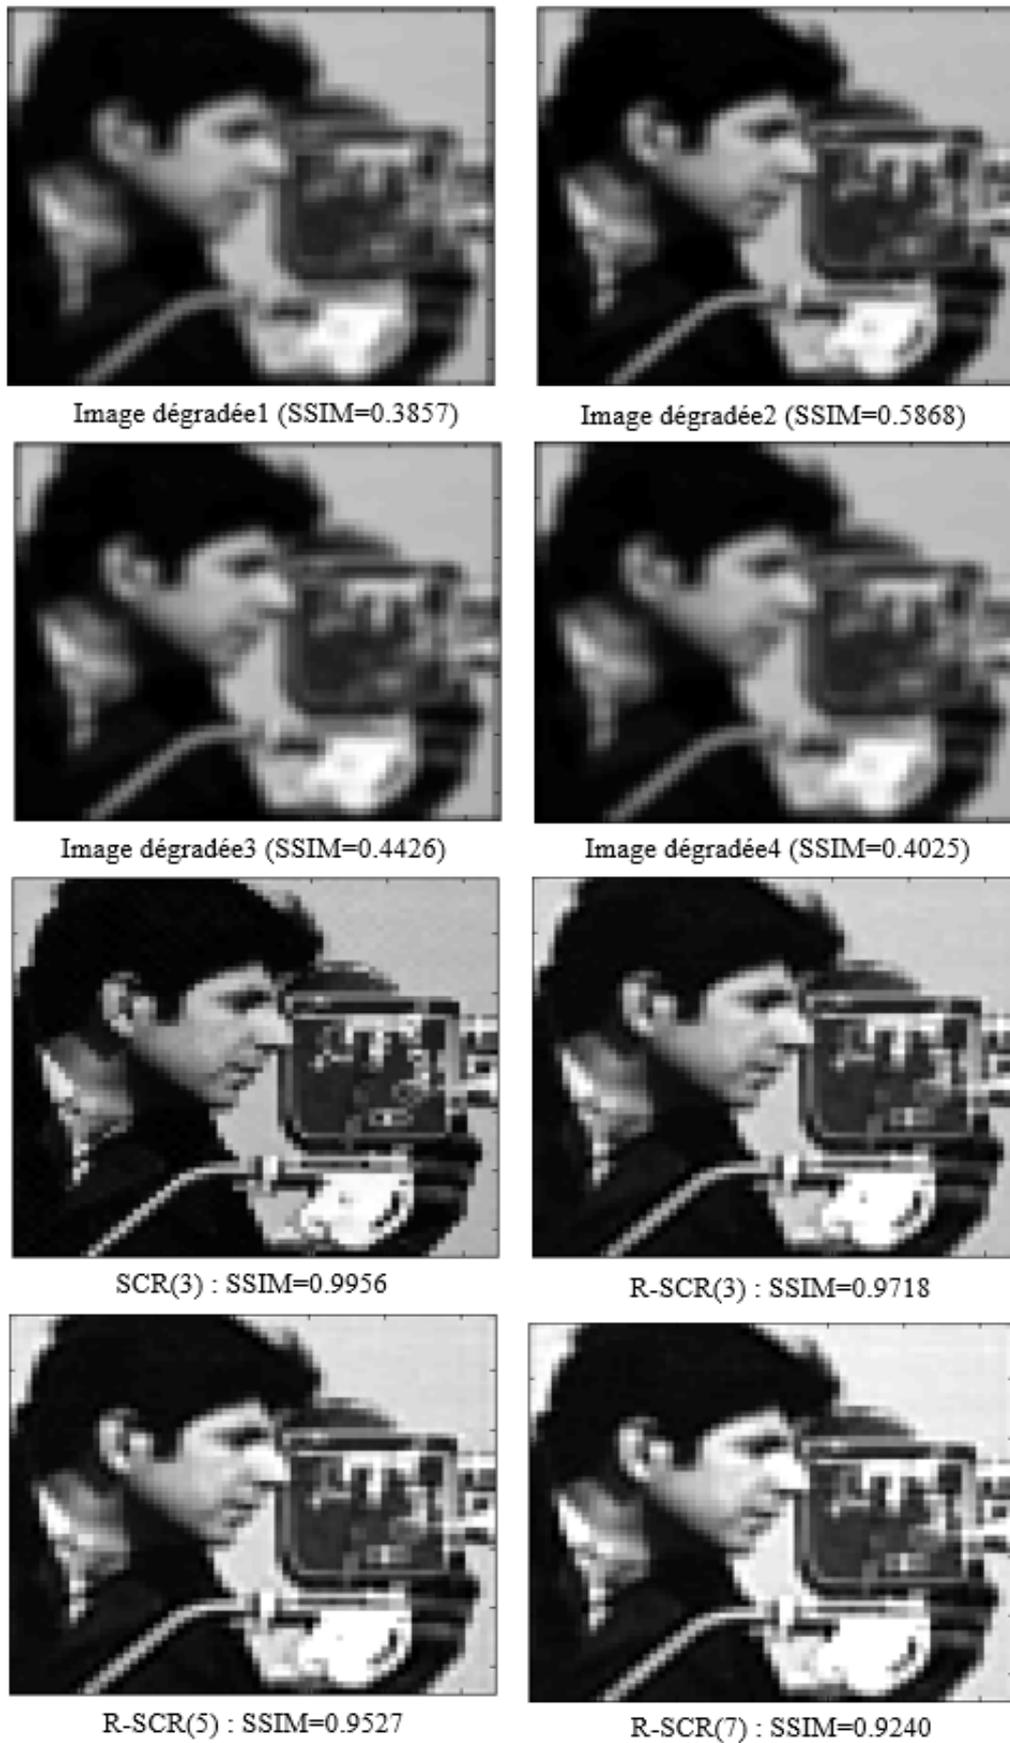


FIGURE 2.12 – Performances des méthodes SCR et R-SCR pour la restauration d'images avec surestimation de l'ordre du canal.

Chapitre 3

Restauration d'images par le décodeur séquentiel 'Stack'

Sommaire

3.1	Introduction	52
3.2	Formulation du problème	53
3.3	Description du décodeur séquentiel Stack	56
3.3.1	Algorithme 'Stack'	56
3.3.2	Améliorations de l'algorithme Stack	58
3.4	Modèle adopté pour la régularisation	60
3.5	Restauration d'images par descente du gradient	63
3.6	Restauration d'images dans le cas d'un système mono-canal (SISO)	64
3.7	Résultats et discussion	66
3.7.1	Évaluation de la version améliorée de l'algorithme Stack	67
3.7.2	Évaluation de la qualité de restauration par l'algorithme Stack	70
3.7.3	Résultats de la restauration par l'algorithme régularisé Stack-TV	71
3.7.4	Amélioration de la restauration par la descente du gradient	72
3.7.5	Étude comparative des algorithmes Stack-TV et ADMM-TV	74
3.7.6	Restauration d'images dans un contexte mono-canal (cas bruité)	74
3.8	Conclusion	75

3.1 Introduction

Dans ce chapitre, nous nous intéressons aux applications pour lesquelles les images enregistrées sont des formes dégradées de la scène initiale en raison d'un ou de plusieurs défauts dans le processus d'imagerie et de capture. Il faut tenir compte d'une grande variété de distorsion et de dégradations de natures différentes, comme le flou (mouvement de la caméra pendant l'exposition, la mise au point ou les lentilles inexactement focalisées), le bruit (effets de dispersion, bruit du capteur), les dégradations géométriques, l'illumination et les imperfections des couleurs (Bovik, 2009; Biemond et al., 1990). Ces dégradations entraînent généralement une perte de qualité visuelle. Il est donc important pour beaucoup de tâches de traitement d'images de neutraliser ces défauts.

La restauration d'images (IR : Image Restoration) à partir d'une ou de plusieurs observations floues et bruitées est un domaine de recherche très important dans le traitement d'image, qui a reçu beaucoup d'intérêt allant des sciences informatiques, l'ingénierie électronique et la télédétection aux sciences médicales et biologiques. La restauration d'images à partir des observations fait partie des problèmes inverses linéaires, qui nécessite la détermination de l'entrée inconnue dans un système linéaire à partir d'une ou de plusieurs sorties connues. De ce fait, l'objectif principal de la restauration d'images est de compenser ou supprimer partiellement les défauts et les imperfections mentionnés précédemment.

La IR peut être formulée comme un problème mal-posé et mal-conditionné, il est donc important de considérer toutes sortes d'informations disponibles, y compris le gain associé à la diversité due au traitement multi-canal (MC : Multi-Channel) d'images. Les résultats préliminaires de la déconvolution multi-canal ont été d'abord développés dans le cas unidimensionnel (1D), puis étendus au cas bidimensionnel (2D). En traitement d'images dans le contexte MC, plusieurs images captées sont observées à partir d'une même scène, cette dernière est dégradée et subie différentes dégradations en traversant plusieurs canaux indépendants. Ce cadre est souvent utilisé dans certaines applications telles que l'imagerie polarimétrique, satellitaire, astronomique et microscopique (Souidene et al., 2009).

Après avoir identifié les canaux (filtres dégradants) de notre système SIMO par le biais des méthodes aveugles proposées (SCR et R-SCR) dans le chapitre précédent, et pour

assurer la restauration de l'image originale, un algorithme de décodage séquentiel basé sur une recherche arborescente a été proposé. Le décodage séquentiel est une technique qui a été initialement développée et utilisée pour restaurer les signaux transmis dans les systèmes de communication avec des canaux bruités. Plusieurs méthodes de décodage existent, telles que le décodage sphérique (SD) (Damen et al., 2003) et l'algorithme Stack (Abediseid and Alouini, 2013). Le décodage sphérique est une technique optimale, mais elle souffre d'une complexité de calcul très élevée pour une grande dimension de l'arbre de recherche (ce qui est le cas dans les problèmes de restauration d'images 2D). Alternative-ment, l'algorithme Stack a été introduit comme une méthode de recherche arborescente pour estimer approximativement un signal au sens du maximum de vraisemblance (ML : Maximum Likelihood) dans les systèmes de communication. Cette technique de recherche efficace et puissante est capable d'offrir une complexité réduite au cours du décodage désiré et permet d'assurer une bonne performance pour la restauration d'images par rapport aux algorithmes connus comme le décodage sphérique (SD : Sphere Decoding) et la méthode de direction alternée des multiplicateurs (ADMM : Alternating Direction Method of Multipliers) développée dans (Jiao et al., 2016).

3.2 Formulation du problème

Notre objectif ici est d'assurer de manière appropriée la restauration d'un système SIMO dans un contexte aveugle, c'est-à-dire que seules les sorties observées du système (les images dégradées) sont connues et utilisées sans connaissance préalable de l'entrée ou du type de dégradation. Cette tâche de restauration d'images peut souvent être formulée comme un problème inverse linéaire mal posé.

Dans le cas des systèmes multi-canal comme l'illustre la figure 3.1 et en tenant compte du fait que l'entrée et les sorties de notre système SIMO sont discrètes, une seule image passe à travers K canaux indépendants ($K > 1$) conduisant à K images dégradées (floues et bruitées).

Dans le domaine spatial, un tel système peut être mathématiquement modélisé pour

chaque pixel $(m, n) : m = 1, \dots, m_g$ et $n = 1, \dots, n_g$, comme suit :

$$\begin{aligned} g_i(m, n) &= h_i(m, n) \star f(m, n) + w_i(m, n) \\ &= \sum_{l_1=0}^{m_h-1} \sum_{l_2=0}^{n_h-1} h_i(l_1, l_2) f(m - l_1, n - l_2) + w_i(m, n) \end{aligned} \quad (3.1)$$

où (\star) est le produit de convolution linéaire, \mathbf{f} désigne l'image source $(m_f \times n_f)$ et \mathbf{g}_i , \mathbf{w}_i , \mathbf{h}_i , désignent les images observées $(m_g \times n_g)$, les matrices de bruit $(m_w \times n_w)$ et les fonctions d'étalement d'un point (PSF)¹ de taille $(m_h \times n_h)$, respectivement pour $i = 1, \dots, K$. Les K filtres causaux estimés précédemment sont suffisamment différents pour satisfaire la condition de diversité dans (Giannakis and Heath, 2000).

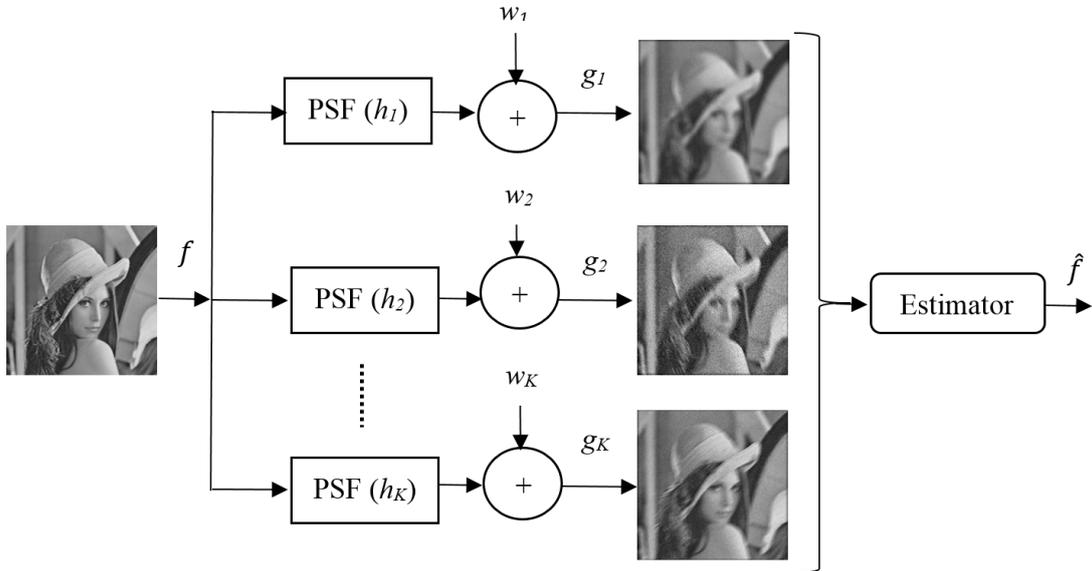


FIGURE 3.1 – Schéma bloc de la dégradation/restauration d'images d'un système SIMO.

En vectorisant les K matrices \mathbf{g}_i et en les empilant dans un seul vecteur \mathbf{g} , nous obtenons la forme du produit matrice-vecteur suivante :

$$\mathbf{g} = [\mathbf{g}_1^T, \mathbf{g}_2^T, \dots, \mathbf{g}_K^T]^T = \mathbf{H} \mathbf{f} + \mathbf{w} \quad (3.2)$$

avec $\mathbf{H} = [\mathbf{H}_1^T, \dots, \mathbf{H}_K^T]^T$, \mathbf{H}_i la matrice de filtrage Toeplitz par blocs associée à la PSF

1. Pour simplifier, nous avons adopté ici une notation causale pour les filtres \mathbf{h}_i .

3.2. FORMULATION DU PROBLÈME

\mathbf{h}_i exprimée par :

$$\mathbf{H}_i = \begin{bmatrix} \mathbf{H}_i(0) & \cdots & \mathbf{H}_i(m_h - 1) & & 0 \\ & \ddots & & \ddots & \\ 0 & & \mathbf{H}_i(0) & \cdots & \mathbf{H}_i(m_h - 1) \end{bmatrix}$$

où

$$\mathbf{H}_i(n) = \begin{bmatrix} h_i(n, 0) & \cdots & h_i(n, n_h - 1) & & 0 \\ & \ddots & & \ddots & \\ 0 & & h_i(n, 0) & \cdots & h_i(n, n_h - 1) \end{bmatrix}$$

Globalement, l'objectif du problème de restauration d'images considéré est de réduire le bruit et de récupérer la formation de l'image perdue en raison du processus de dégradation. La restauration de l'image est ici réalisée en estimant l'image idéale $\hat{\mathbf{f}}$, aussi proche que possible de l'image originale \mathbf{f} , connaissant uniquement les images observées (floues et/ou bruitées) \mathbf{g}_i . Selon l'équation (3.2) et avec les filtres du canal déjà identifiés, l'estimation de $\hat{\mathbf{f}}$ est assurée en utilisant l'approche du maximum de vraisemblance.

Si nous supposons que le vecteur de bruit additif \mathbf{w} est blanc et Gaussien, la restauration de \mathbf{f} peut être effectuée au sens des moindres carrés (LS : Least Square) en minimisant la métrique² donnée par la distance euclidienne suivante :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in A} \|\mathbf{g} - \mathbf{H} \mathbf{f}\|_2^2 \quad (3.3)$$

où $\|\cdot\|_2$ représente la norme l_2 et l'alphabet A désigne le treillis associé aux valeurs des pixels en niveau de gris variant dans la plage $[0, 255]$. Comme prétraitement pour la progression de notre algorithme IR, nous appliquons une décomposition QR standard à la matrice de filtrage Toeplitz \mathbf{H} . Ainsi, le précédent problème des moindres carrés de l'équation (3.3) peut être réécrit comme suit :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in A} \|\mathbf{g}' - \mathbf{R} \mathbf{f}\|_2^2 \quad (3.4)$$

où $\mathbf{g}' = \mathbf{Q}^T \mathbf{g}$ et \mathbf{R} est la matrice triangulaire supérieure carrée obtenue à partir de la

2. Cette métrique serait la norme l_1 si notre bruit est de type Laplacien.

décomposition QR précédente.

3.3 Description du décodeur séquentiel Stack

3.3.1 Algorithme ‘Stack’

En utilisant les K images dégradées, l’algorithme Stack qui est un décodeur efficace de recherche arborescente tente de trouver le *meilleur chemin* le long de tout l’arbre de décodage. Dans cette section, nous détaillons le mécanisme de l’algorithme Stack en présentant brièvement ses différentes étapes. Avant de procéder à la description d’un tel algorithme, nous discutons d’abord la métrique M nécessaire pour le décodage séquentiel.

A partir du critère des moindres carrés donné précédemment par l’équation (3.4), notre décodeur est fondamentalement basé sur la minimisation de la métrique M d’un chemin, que nous pouvons définir au $k^{\text{ième}}$ niveau de l’arbre, comme suit :

$$M(\mathbf{f}^k) = \|\mathbf{g}'^k - \mathbf{R}_{kk} \mathbf{f}^k\|_2^2 \quad (3.5)$$

Avec :

- $\mathbf{f}^k = [f_k, \dots, f_2, f_1]^T$ désigne les k dernières composantes du vecteur à estimer \mathbf{f} ,
- \mathbf{g}'^k est formé par les k dernières composantes du vecteur des observations \mathbf{g}' ,
- \mathbf{R}_{kk} est la partie inférieure $k \times k$ de la matrice triangulaire supérieure \mathbf{R} , donnée par :

$$\mathbf{R}_{kk} = \begin{bmatrix} r_{kk} & \cdots & r_{k1} \\ & \ddots & \vdots \\ 0 & & r_{11} \end{bmatrix}$$

Durant le processus d’estimation par l’algorithme Stack, pour déterminer le meilleur (optimal) chemin le long de l’arbre de recherche (voir figure 3.2), une valeur est attribuée à chaque nœud de l’arbre. Cette valeur est appelée ‘la métrique’, elle est donnée par l’équation (3.5). Le décodeur Stack est appliqué sur un arbre d -ary avec $d = 256$ où chaque niveau k de l’arbre représente une valeur d’un pixel du vecteur \mathbf{f} à estimer. Pour chaque niveau k , les nœuds désignent un alphabet A des valeurs des niveaux de gris

$([0, 255])$ des pixels de l'image.

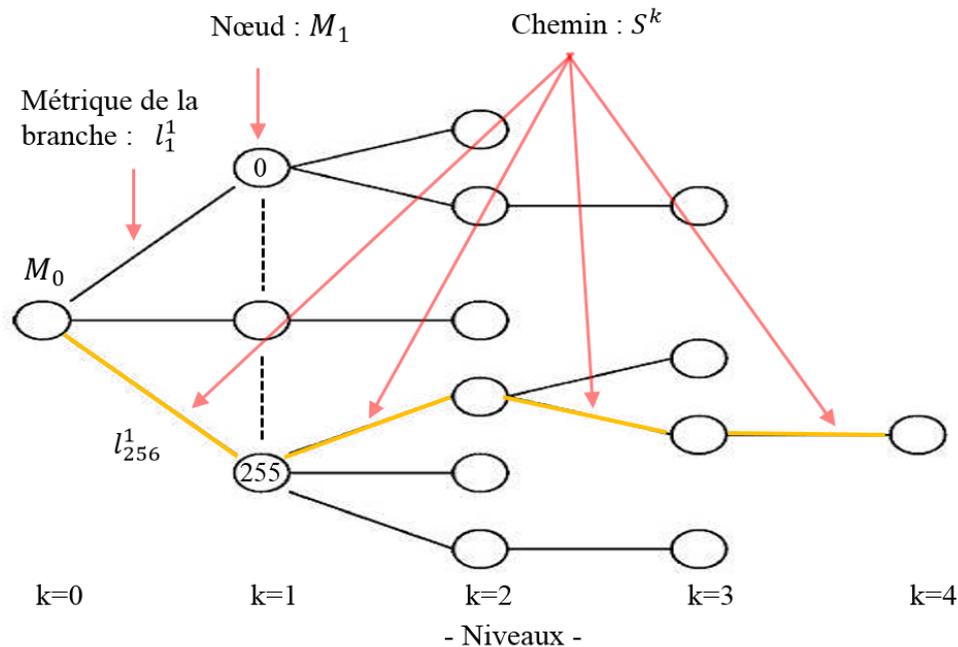


FIGURE 3.2 – Exemple d'arborescence pour $(K = 4)$ niveaux.

Le mécanisme de décodage par l'algorithme Stack est brièvement décrit par l'organigramme de la figure 3.3. Après initialisation du nœud initial ($k = 0$) de l'arbre, chaque étape de décodage consiste à étendre la recherche vers le prochain et le meilleur nœud parmi les 256 possibles, afin de trouver le chemin optimal, M en minimisant l'ensemble des métriques associées aux différentes branches qui constituent ce chemin. La sélection conjointe des nœuds suivants et des meilleurs nœuds durant l'étape de décodage est assurée par l'utilisation de l'énumération Schnorr-Euchner (Hassibi and Vikalo, 2005) qui sert à générer des nœuds avec un tri en ordre croissant de leurs métriques. Finalement, le processus d'estimation s'arrête lorsque le chemin optimal atteint la fin ($k = K$) de l'arbre (Jelinek, 1969).

En résumé, les étapes de l'algorithme sont les suivantes :

- Au début du processus de décodage, la pile de stockage contient uniquement le nœud initial de l'arbre (c'est-à-dire le chemin vide) dont sa métrique initialisée arbitrairement à zéro ($M_0 = 0$).
- L'opération de décodage consiste à trouver le chemin S^k qui correspond à la métrique M_k au sommet de la pile (c'est-à-dire la métrique avec la plus petite valeur

dans la pile), en éliminant M_k de la pile, en calculant les métriques $l_{k+1}^1, \dots, l_{k+1}^d$ des branches qui quittent le dernier nœud du chemin S^k , et en insérant la nouvelle métrique du chemin $M_{k+1}^i = M_k + l_{k+1}^i$, $i = 1, 2, \dots, d$, dans leurs positions appropriées selon leur taille (clairement la pile contient les identifiants des chemins et leurs métriques).

- La recherche le long de l'arbre se termine lorsque le décodeur atteint le sommet de la pile avec un chemin dont la longueur est égale à la taille de l'arbre (c'est-à-dire la taille du vecteur \mathbf{f} à estimer $m_f \times n_f$).

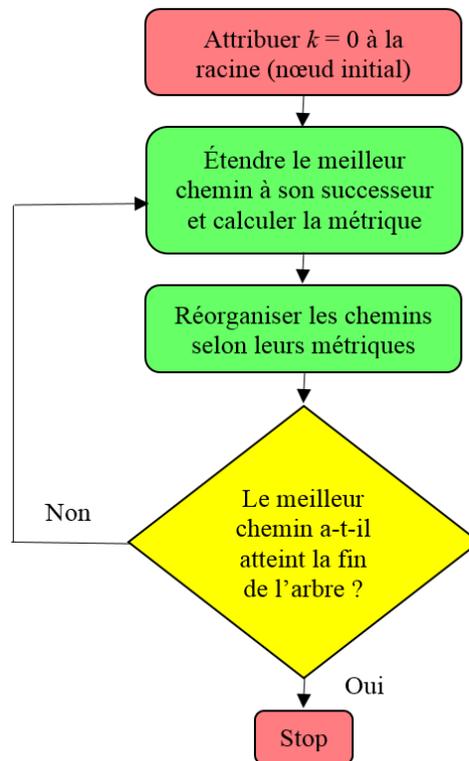


FIGURE 3.3 – Mécanisme du décodage par l'algorithme Stack.

3.3.2 Améliorations de l'algorithme Stack

L'un des problèmes majeurs de la restauration d'images est la complexité en temps des algorithmes. Dans cette section, nous présentons une version à coût réduit de l'algorithme Stack. Les améliorations proposées sont basées sur deux caractéristiques principales. La première est liée à la structure de la matrice de convolution \mathbf{H} qui est à bande limitée (BL : Band limited). La deuxième est une sorte de quantification suivant le nombre de classes dans l'arbre de recherche (Boudjenouia et al., 2016c). Ces améliorations sont détaillées

3.3. DESCRIPTION DU DÉCODEUR SÉQUENTIEL STACK

ci-dessous :

1. *Matrice de filtrage à bande limitée* : Étant donné que la matrice de convolution (filtrage) \mathbf{H} est caractérisée par sa structure à bande limitée. Nous obtenons par conséquent après une décomposition QR, une matrice triangulaire supérieure, \mathbf{R} caractérisée de la même façon par une structure à bande limitée (voir figure 3.4). En effet, la taille de la bande B de la matrice triangulaire \mathbf{R} dépend à la fois de la taille de l'image dégradée ($m_g \times n_g$) et de celle du filtre dégradant ($m_h \times n_h$). La bande limitée est formulée comme suit :

$$B = m_h n_h + (m_h - 1)(m_g - 1) \quad (3.6)$$

À ce stade et en utilisant cette version améliorée de l'algorithme stack, le processus d'optimisation du critère au sens des moindres carrés prends en compte, seuls les B éléments non nuls pendant le produit matrice-vecteur. Ceci permet de réduire considérablement le coût de calcul, tel qu'illustré dans la section 3.7 (résultats et discussion).

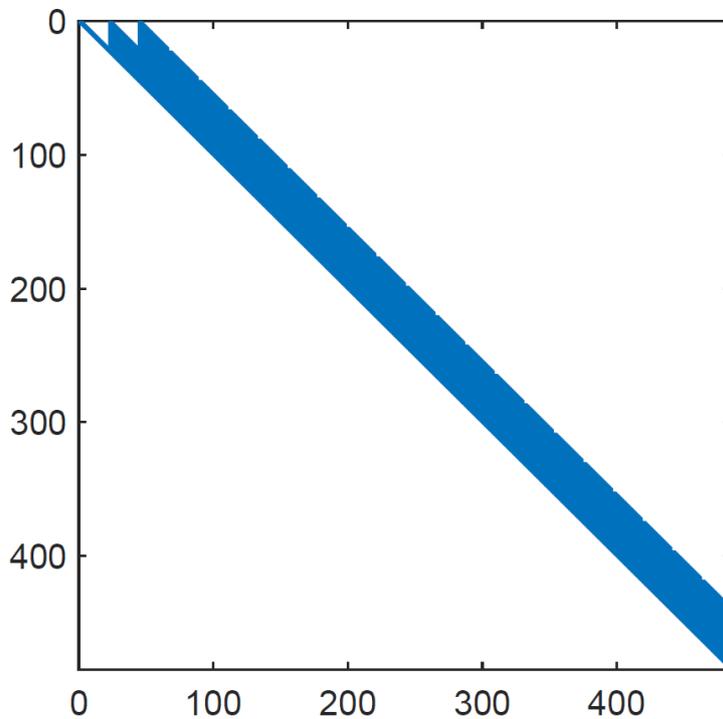


FIGURE 3.4 – Structure à bande limitée de la matrice de filtrage \mathbf{R} .

2. *Approche hiérarchique de l'algorithme Stack* :

La deuxième amélioration que nous proposons est basée sur la quantification (restriction) des niveaux de gris $[0, 255]$ de l'image à traiter. Ainsi, l'intervalle est divisé en 2^N classes ($N < 8$). Pour chaque classe, la valeur de son centre est attribuée à un nœud de l'arbre.

Par conséquent, la recherche le long de l'arbre se fait en deux étapes : les recherches globales et celles raffinées. Ceci conduit à une métrique de branche à minimiser par nœud comme suit :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in A} \|\mathbf{g}' - \mathbf{R}(\mathbf{f}_G + \mathbf{f}_R)\|_2^2 \quad (3.7)$$

où \mathbf{f}_G correspond au vecteur d'image principal (pour lequel les entrées appartiennent à un alphabet de taille 2^N). \mathbf{f}_R est la version raffinée de l'image restaurée prenant des valeurs dans un alphabet de taille 2^{8-N} éléments.

Étape 1 : Dans ce cas, la recherche est effectuée en tenant compte d'un treillis associé aux 2^N classes :

$$\hat{\mathbf{f}}_G = \arg \min_{\mathbf{f} \in A_G} \|\mathbf{g}' - \mathbf{R} \mathbf{f}_G\|_2^2 \quad (3.8)$$

Étape 2 : Cette étape consiste à améliorer l'image, déjà restaurée par l'étape précédente, selon le critère suivant :

$$\hat{\mathbf{f}}_R = \arg \min_{\mathbf{f} \in A_R} \|\hat{\mathbf{g}} - \mathbf{R} \mathbf{f}_R\|_2^2 \quad (3.9)$$

où $\hat{\mathbf{g}} = \mathbf{g}' - \mathbf{R} \hat{\mathbf{f}}_G$.

L'image résultante de cette approche hiérarchique est donnée par la somme des deux images estimées, comme suit :

$$\hat{\mathbf{f}} = \hat{\mathbf{f}}_G + \hat{\mathbf{f}}_R$$

3.4 Modèle adopté pour la régularisation

Pour faire face aux imperfections indésirables causées par le bruit additif \mathbf{w} , nous introduisons comme terme additionnel dans la fonction coût de notre système, un modèle

3.4. MODÈLE ADOPTÉ POUR LA RÉGULARISATION

approprié de régularisation, réalisé par l'approche connue de variation totale (TV). Les techniques de minimisation basées sur la TV ont été largement utilisées avec succès dans de nombreuses applications. A l'origine cette technique a été développée dans (Rudin et al., 1992) en tant que modèle (ROF : Rudin, Osher et Fatemi) pour le débruitage des images et étendu par la suite pour le défloutage.

Plus précisément en traitement d'images, l'approche TV, en tant qu'outil de régularisation, comparée à celle de Tikhonov (Tikhonov et al., 1977), s'est révélée très efficace pour préserver les discontinuités (tout en créant des zones lisses), et les contours des objets qui sont généralement les caractéristiques les plus importantes à récupérer.

À partir de l'équation (3.4), notre version régularisée de l'algorithme Stack, nommée Stack-TV (Boudjenouia et al., 2016c), basée sur la TV discrète, résout le problème variationnel de minimisation régularisée, exprimé comme suit :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in \mathcal{A}} \|\mathbf{g}' - \mathbf{R} \mathbf{f}\|_2^2 + \alpha \|\mathbf{f}\|_{TV} \quad (3.10)$$

où α est un paramètre de régularisation positif qui équilibre les deux termes de minimisation et fournit un compromis entre la fidélité des mesures et la sensibilité au bruit. $\|\cdot\|_{TV}$ est la norme TV discrète que nous pouvons définir sous la forme d'une norme ℓ_1 ou ℓ_2 comme :

$$\|\mathbf{f}\|_{TV} = \sum \|\nabla \mathbf{f}\|_2 \quad \text{ou} \quad \|\mathbf{f}\|_{TV} = \sum \|\nabla \mathbf{f}\|_1$$

En outre, pour une image donnée \mathbf{f} ($m_f \times n_f$), l'opérateur gradient discret ∇ est défini par $\nabla \mathbf{f} = (\nabla_1 \mathbf{f}, \nabla_2 \mathbf{f})$, où ∇_1 et ∇_2 sont deux opérateurs linéaires de différenciation (horizontal et vertical) exprimés pour chaque pixel (i, j) , comme suit :

$$\begin{cases} \nabla_1 f(i, j) = f(i+1, j) - f(i, j), & i = 1, \dots, m_f - 1 \\ & j = 1, \dots, n_f \\ \nabla_2 f(m_f, j) = f(1, j) - f(m_f, j), & j = 1, \dots, n_f \end{cases} \quad (3.11)$$

et

$$\begin{cases} \nabla_2 f(i, j) = f(i, j+1) - f(i, j), & i = 1, \dots, m_f \\ & j = 1, \dots, n_f - 1 \\ \nabla_2 f(i, n_f) = f(i, 1) - f(i, n_f), & i = 1, \dots, m_f \end{cases} \quad (3.12)$$

Durant le processus d'estimation de l'image originale \mathbf{f} et en se basant sur une régularisation de type TV, nous pouvons considérer ici deux modèles d'optimisation différents, formulés comme suit :

— Le modèle TV-isotrope pour la restauration :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in A} \|\mathbf{g}' - \mathbf{R} \mathbf{f}\|_2^2 + \alpha \sum \sqrt{|\nabla_1 \mathbf{f}|^2 + |\nabla_2 \mathbf{f}|^2}$$

— Le modèle TV-anisotrope :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in A} \|\mathbf{g}' - \mathbf{R} \mathbf{f}\|_2^2 + \alpha \sum |\nabla_1 \mathbf{f}| + |\nabla_2 \mathbf{f}|$$

où \sum désigne la somme sur tous les pixels de l'image.

En revanche, étant donné que la forme du terme de régularisation TV dans l'équation (3.10) ne suit pas la forme du critère d'optimisation requise par la structure de décodage exigée par l'algorithme, des approximations sont introduites. Par conséquent, du point de vue algèbre linéaire, le terme de régularisation TV, peut être vu sous la forme d'une multiplication matrice-vecteur.

Afin de satisfaire une présentation matricielle triangulaire supérieure de la régularisation TV, les deux opérateurs linéaires de différenciation (horizontal et vertical) donnés par les équations (3.11) et (3.12), peuvent être reformulés en tant que produit matrice-vecteur, comme suit :

$$\nabla_1 \mathbf{f} = \mathbf{D}_1 \mathbf{f} \quad \text{et} \quad \nabla_2 \mathbf{f} = \mathbf{D}_2 \mathbf{f}$$

sation basée sur la descente du gradient (Andrei, 2004).

Dans l'équation (3.13), la fonction $Q(\mathbf{f})$ est différentiable et désigne la forme proposée du critère combiné à minimiser. Cette fonction est exprimée comme suit :

$$Q(\mathbf{f}) = \|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2 + \beta \Psi(\nabla \mathbf{f}) \quad (3.14)$$

où la constante positive β est fixée aussi de manière *ad-hoc*, afin d'équilibrer les termes suivants du critère hybride :

- $\|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2$ donne la somme des résidus carrés afin de minimiser les différences entre l'image dégradée et l'image estimée.
- $\nabla \mathbf{f}$ est le gradient de l'image, précédemment défini et utilisé pour préserver les plus importantes caractéristiques dans les images, telles que les bords (contours) des objets.
- Ψ est une fonction convexe proposée dans (Jiao et al., 2016) et définie par $\Psi(\cdot) = \|\cdot\|_{l_1} + \frac{\nu}{2} \|\cdot\|_2^2$ pour la valeur fixe de $\nu = 1e - 3$.

3.6 Restauration d'images dans le cas d'un système mono-canal (SISO)

Le problème conventionnel de la restauration d'images est souvent consacré à la restauration d'une seule image (entrée unique) à partir d'une seule image dégradée observée (sortie unique), c'est à dire un système à entrée-unique sortie-unique (SISO), schématisé par la figure 3.5. Dans la littérature, il existe plusieurs études consacrées à la restauration SISO.

Dans cette section, nous utilisons l'algorithme Stack-TV pour restaurer des images dans le cas mono-canal. Tout d'abord, nous montrons comment l'algorithme proposé peut être adapté correctement au contexte SISO.

En reprenant la même formulation que pour un système SIMO donnée par l'équation (3.1). Pour $K = 1$, le modèle de la restauration exprimé pour chaque pixel (m, n) , peut

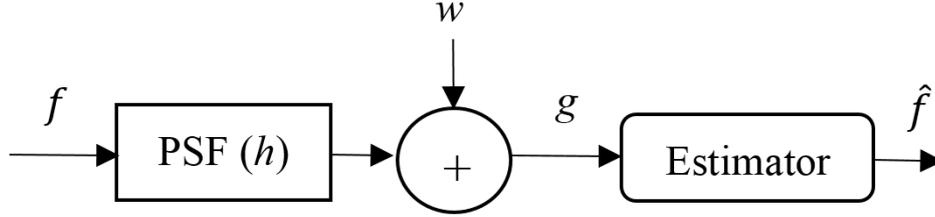


FIGURE 3.5 – Modèle de restauration d'images dans un contexte mono-canal.

être mathématiquement formulé comme suit :

$$\begin{aligned} g(m, n) &= h(m, n) \star f(m, n) + w(m, n) \\ &= \mathbf{H} \mathbf{f}(m, n) + \mathbf{w}(m, n) \end{aligned} \quad (3.15)$$

où la matrice de convolution \mathbf{H} , associée à la PSF \mathbf{h} , est Toeplitz et formée de la même manière que dans le cas d'un système SIMO.

Malheureusement, par rapport au cas multi-canal détaillé précédemment, la restauration pour le mono-canal est un problème fortement mal-posé et mal conditionné. C'est pourquoi il est nécessaire de surmonter ces difficultés. Il est fréquent pour résoudre le problème de conditionnement de la matrice de filtrage \mathbf{H} , d'utiliser une initialisation adéquate pour l'algorithme proposé. Afin de rendre robuste ce dernier aux effets indésirables du bruit, un terme de régularisation de type TV, est intégré dans le critère des moindres carrés à minimiser.

Afin d'assurer le bon conditionnement de la matrice de convolution \mathbf{H} et pour adapter le processus d'optimisation (ici SISO) avec la structure appropriée à la recherche arborescente requise par l'algorithme Stack-TV, la convolution est réalisée à l'aide de l'opération dite 'Zero-padding'. Le processus d'estimation, quant à lui est fait colonne par colonne. A ce stage, la restauration de \mathbf{f} peut être effectuée en minimisant le critère des moindres carrés exprimé pour chaque colonne ($c = 1, \dots, n_f$) comme suit :

$$\begin{aligned} \hat{\mathbf{f}}_{c+1} &= \arg \min_{\mathbf{f}_{c+1} \in A} \|\mathbf{g}_c - (\mathbf{H}_{c-1} \mathbf{f}_{c-1} + \mathbf{H}_c \mathbf{f}_c + \mathbf{H}_{c+1} \mathbf{f}_{c+1})\|_2^2 \\ &= \arg \min_{\mathbf{f}_{c+1} \in A} \|\tilde{\mathbf{g}}_c - \mathbf{H}_{c+1} \mathbf{f}_{c+1}\|_2^2 \end{aligned} \quad (3.16)$$

où : $\tilde{\mathbf{g}}_c = \mathbf{g}_c - \mathbf{H}_{c-1} \mathbf{f}_{c-1} - \mathbf{H}_c \mathbf{f}_c$.

D’où nous formulons notre critère à minimiser au sens des moindres carrés, comme suit :

$$\hat{\mathbf{f}}_{c+1} = \arg \min_{\mathbf{f}_{c+1} \in A} \|\mathbf{g}'_c - \mathbf{R}_{c+1} \mathbf{f}_{c+1}\|_2^2 \quad (3.17)$$

avec $\mathbf{g}'_c = \mathbf{Q}_{c+1}^T \tilde{\mathbf{g}}_c$ et \mathbf{R}_{c+1} la matrice triangulaire supérieure carrée obtenue à partir de la décomposition QR de \mathbf{H}_{c+1} .

Cette structure nous offre un décodage approprié avec l’algorithme Stack-TV, mais malheureusement, elle souffre de l’obligation d’une initialisation. Cette dernière est nécessaire pour l’estimation du premier vecteur, c’est-à-dire lorsque ($c = 1$). En outre, une régularisation de type TV est également choisie pour ce cas de la restauration mono-canal.

3.7 Résultats et discussion

Dans cette section, un ensemble d’expériences sont réalisées pour étudier l’efficacité et les performances de la méthode proposée (Stack-TV). Nous rappelons que le décodage séquentiel, Stack-TV est dédié à la restauration d’images dans les cas mono et multi-canal, avec connaissance a priori des filtres dégradants surestimés auparavant dans le chapitre précédent (Chapitre 2). Pour des fins de comparaison, notre méthode est comparée à la technique de direction alternée des multiplicateurs (ADMM : Alternating Direction Method of Multipliers) proposée par (Jiao et al., 2016).

Dans toutes les expérimentations, nos approches sont appliquées à une variété d’images dégradées (floues/bruitées) générées. Tout d’abord, par l’application d’un flou sur chacune des images. Ensuite, par ajout de bruit blanc Gaussien avec différents écarts types (σ_{noise}). Par ailleurs, afin d’évaluer nos algorithmes, les images en niveau de gris Cameraman (256×256), Lena (512×512) et Pirate (512×512) ont été choisies comme vecteurs de test. Les filtres dégradants inconnus (précédemment estimés) ont des formes différentes comme ‘Gaussian’, ‘Motion’, ‘Disk’ et ‘Average’ et leurs paramètres seront définis pour chaque expérience selon le cas traité.

3.7. RÉSULTATS ET DISCUSSION

Afin de comparer les résultats de la restauration d'images, le rapport signal/bruit de crête (PSNR) en dB et l'indice de similarité structurelle (SSIM), sont utilisés et exprimés comme suit :

$$PSNR = 10 \times \log \frac{255^2}{MSE} \quad [dB] \quad (3.18)$$

$$SSIM = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \times \frac{2\sigma_{fg} + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (3.19)$$

où MSE est l'erreur quadratique moyenne par pixel, μ_f , μ_g sont les moyennes et σ_f^2 , σ_g^2 les variances de \mathbf{f} et \mathbf{g} , respectivement. σ_{fg} la covariance de \mathbf{f} et \mathbf{g} . C_1 et C_2 sont des constantes exprimées comme suit :

$$C_1 = (K_1 \times L)^2 \quad \text{et} \quad C_2 = (K_2 \times L)^2$$

avec L , est la dynamique des valeurs des pixels (soit $L = 255$ pour les images codées sur 8 bits), et les constantes, K_1 et K_2 sont égales à 0.01 et 0.03, respectivement.

3.7.1 Evaluation de la version améliorée de l'algorithme Stack

Matrice de filtrage à bande limitée

Les deux versions de l'algorithme Stack (avec et sans exploitation de la structure à bande limitée) ont été appliquées à une portion de l'image Cameraman avec différentes tailles (32×32 , 50×50 , 64×64 et 128×128) dégradée par un filtre passe bas (flou) de taille ($[3, 3]$, $[4, 4]$, $[5, 5]$ et $[6, 6]$) et corrompu par un bruit blanc Gaussien additif. Nous réalisons 100 simulations Monte-Carlo avec différentes valeurs de bruit dans l'ensemble $\{5, \dots, 40\}$ dB.

Le tableau 3.1 montre le gain considérable obtenu en terme de coût de calcul (allant de **61%** à **73%** en fonction de la taille de l'image et celle du flou) lorsque la structure à bande limitée de la matrice triangulaire \mathbf{R} est exploitée.

TABLE 3.1 – Gain en coût de calcul de l’algorithme Stack avec utilisation de la structure BL.

Coût de calcul gain (%)	Taille du flou [3, 3]	Taille du flou [4, 4]	Taille du flou [5, 5]	Taille du flou [6, 6]
Image (32 × 32)	61.02	63.19	63.74	64.12
Image (50 × 50)	71.21	71.16	67.12	66.95
Image (64 × 64)	73.38	71.57	67.24	65.15
Image (128 × 128)	71.19	68.67	67.47	64.77

Intérêts de l’approche hiérarchique

Dans cette section, deux expériences sont menées pour illustrer l’intérêt d’utiliser l’approche hiérarchique. Tout d’abord, en élargissant l’intervalle de recherche pour l’étape raffinée. Ensuite, selon le nombre des étapes (globale ou raffinée). Pour les deux cas, nous appliquons cette approche hiérarchique à des images affectées par trois types de flou (voir figure 3.6) : ‘Motion’ avec un mouvement linéaire de 3 pixels dans la direction de 30 degrés et un flou ‘Gaussian’ de taille [3, 3] avec les écarts types suivants ($\sigma_1 = 1, 5$; $\sigma_2 = 5$).

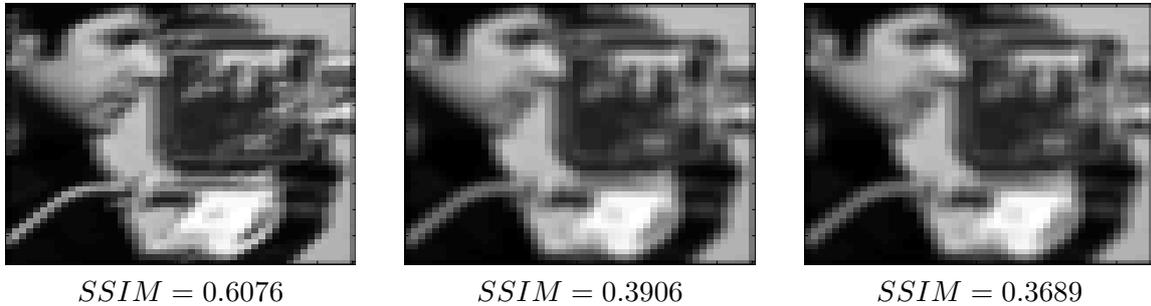


FIGURE 3.6 – Images utilisées pour l’approche hiérarchique et dégradées par trois types de flou.

Dans le premier cas, nous évaluons notre approche en fixant le nombre 2^N de classes $\{2, 4, \dots, 128\}$ de la première étape (recherche globale) combinée à un intervalle élargie de la plage de recherche pour l’étape raffinée (c’est-à-dire la deuxième étape) avec $2^{8-N} \{N = 1, 2, \dots, 7\}$ classes.

La figure 3.7 montre les résultats de restauration de l’étape globale ($SSIM = 0.9694$) suivi par sa version raffinée ($SSIM = 0.9772$) dans le cas de 32 classes ($N = 5$).

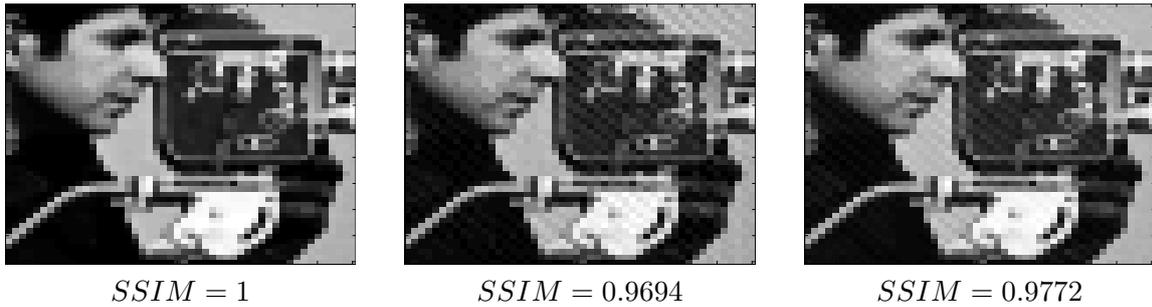


FIGURE 3.7 – Restauration d’images avec l’approche hiérarchique avec 32 classes ($N = 5$). Image originale, grossière et raffinée (de gauche à droite).

Les tableaux 3.2 et 3.3 montrent une petite perte de qualité de restauration (p. ex. **-0.91 %** pour 64 classes, **-2.28%** pour 32 classes). Cette perte est compensée par un important gain en coût de calcul (p. ex. **+92.6%** pour 64 classes, **+94.34%** pour 32 classes). Ainsi, pour le même nombre de classes, la perte en qualité de restauration est proportionnelle à l’élargissement de l’intervalle de recherche et inversement proportionnelle en terme du coût de calcul.

TABLE 3.2 – Évolution du coût de calcul en fonction de l’élargissement de recherche (étape raffinée).

Coût de calcul gain (%)	2^{8-N} $N = 1$	2^{8-N} $N = 2$	2^{8-N} $N = 3$	2^{8-N} $N = 4$	2^{8-N} $N = 5$	2^{8-N} $N = 6$	2^{8-N} $N = 7$
2 classes	88.06	-	-	-	-	-	-
4 classes	88.06	92.97	-	-	-	-	-
8 classes	89.13	92.59	94.27	-	-	-	-
16 classes	89.13	91.25	93.74	94.33	-	-	-
32 classes	89.13	91.25	92.74	93.89	94.34	-	-
64 classes	89.13	89.29	89.67	91.08	91.99	92.6	-
128 classes	89.13	89.29	89.67	89.73	89.79	89.82	89.88

Dans le deuxième cas, nous évaluons notre approche hiérarchique en procédant par une succession d’étapes (globale et raffinée). Les simulations comparent les performances d’exécution entre 2 et 3 étapes. Les performances en qualité de restauration pour 2 étapes varient entre **0.02%** et **0.05%** et ceci pour les situations suivantes (16, 32, 64)-(8, 16, 32, 64) classes. Dans le cas de 3 étapes, elles varient entre **0.01%** et **0.06%** pour les configurations données par (16, 32, 64)-(16, 32, 64)-(8,16,32) classes. Par conséquent, les performances de la restauration dans cette approche hiérarchique s’améliorent en fonction de l’élargissement des intervalles de recherche (étape raffinée) comparées à la succession

TABLE 3.3 – Évolution de la qualité de restauration en fonction de l’élargissement de recherche (étape raffinée).

SSIM gain (%)	2^{8-N} $N = 1$	2^{8-N} $N = 2$	2^{8-N} $N = 3$	2^{8-N} $N = 4$	2^{8-N} $N = 5$	2^{8-N} $N = 6$	2^{8-N} $N = 7$
2 classes	-12.85	-	-	-	-	-	-
4 classes	-5.97	-11.98	-	-	-	-	-
8 classes	-0.2	-6.87	-8.09	-	-	-	-
16 classes	0	-0.05	-2.5	-4.31	-	-	-
32 classes	0	0	-0.26	-1.62	-2.28	-	-
64 classes	0	0	0	-0.09	-0.75	-0.91	-
128 classes	0	0	0	0	-0.12	-0.24	-0.27

des étapes (globale et raffinée) où le gain atteint est très faible.

3.7.2 Évaluation de la qualité de restauration par l’algorithme Stack

Défloutage (cas sans bruit)

Dans cette section, les filtres dégradants précédemment surestimés par notre méthode R-SCR avec un ordre de surestimation ($\tilde{m}_h = \tilde{n}_h = 5$), sont utilisés pour effectuer quelques simulations de défloutage des images (cas sans bruit). Les images originales (A : Pirate (512×512)), (B : Parrot (256×256)), (C : Cameraman (512×512)) et (D : Lena (512×512)), chacune est dégradée par un flou ‘Motion’ avec un mouvement linéaire de 20 pixels dans la direction 45 degrés, un flou ‘Disk’ avec un rayon $r = 5$ et un flou ‘Gaussian’ de taille $[3, 3]$ avec un écart type, $\sigma \in [0.5, 1]$. Comme le montre la figure 3.8, toutes les images dégradées sont parfaitement restaurées avec une erreur $MSE = 0$ et un indice $SSIM = 1$ pour ces images défloutées.

Restauration d’images dans un contexte multi-canal (cas bruité)

Dans cette simulation, en plus de la dégradation causée par le flou (‘Gaussian’ et ‘Motion’), les images sont aussi dégradées par l’ajout d’un bruit blanc gaussien additif (Cameraman : (A : $PSNR = 20.26$ dB, $SSIM = 0.60$; B : $PSNR = 21.07$ dB, $SSIM =$



FIGURE 3.8 – (A, B, C, D) : Images floues. (A', B', C', D') : Images restaurées à l'aide de l'algorithme proposé.

0.63 ; C : $PSNR = 21.66$ dB, $SSIM = 0.65$), Lena : (A' : $PSNR = 22.95$ dB, $SSIM = 0.605$; B' : $PSNR = 21.62$ dB, $SSIM = 0.623$; C' : $PSNR = 21.81$ dB, $SSIM = 0.647$) avec $SNR = \{20, 25\}$ dB, respectivement. Dans un contexte multi-canal ($K = 3$) et sans recours à la régularisation, la figure 3.9 montre les images restaurées à l'aide de notre algorithme Stack (Cameraman : (D : $PSNR = 20.703$ dB, $SSIM = 0.55$), Lena : (D' : $PSNR = 20.254$ dB, $SSIM = 0.564$)).

Les résultats montrent clairement l'efficacité de l'algorithme proposé. Ceci est due principalement à la diversité offerte par le multi-canal qui permet d'améliorer le bon-conditionnement de la matrice de filtrage \mathbf{H} . Cependant, l'effet indésirable du bruit est encore important et c'est pour cela qu'une régularisation est nécessaire pour une meilleure restauration.

3.7.3 Résultats de la restauration par l'algorithme régularisé Stack-TV

Dans cette section, nous présentons les résultats obtenus lorsque nous utilisons notre version régularisée, Stack-TV de l'algorithme Stack (équation (3.10)), en utilisant les deux termes de régularisation $\|\mathbf{f}\|_{TV}$ (avec les normes ℓ_1 et ℓ_2). Tout d'abord, le paramètre de régularisation α , qui contrôle le compromis entre les deux termes du critère à optimiser

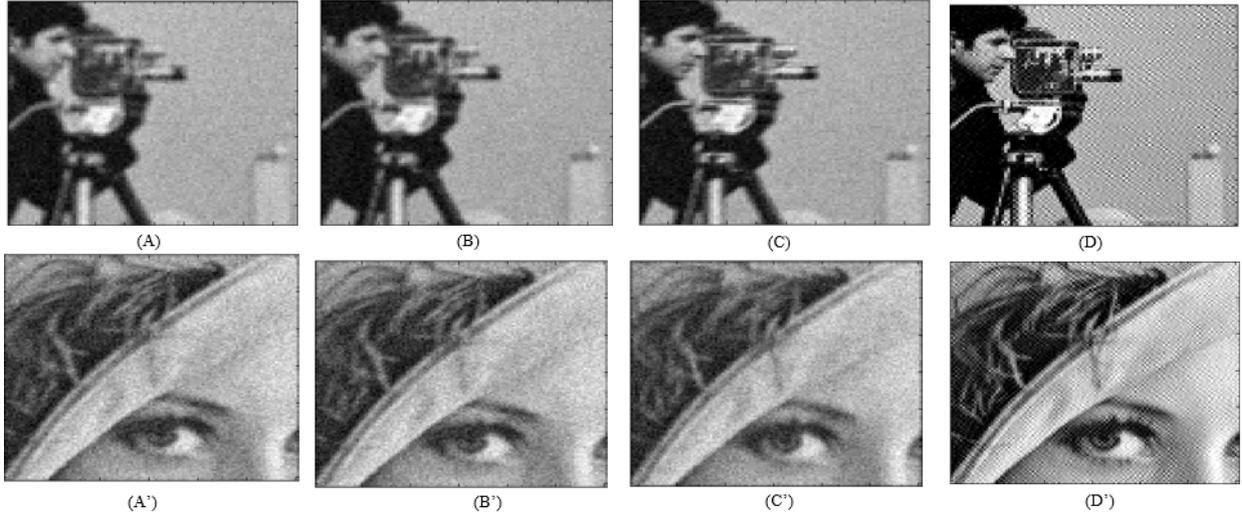


FIGURE 3.9 – (A, B, C, A', B', C') : Images floues bruitées, (D, D') : Résultats de la restauration dans le cas multi-canal.

et représente la quantité de régularisation est fixé de manière *ad-hoc* à $\alpha = 1.5e^{-2}$ et $2e^{-2}$ pour les images Cameraman et Lena, respectivement.

La figure 3.10 montre les effets de la régularisation (sans régularisation : (A : $PSNR = 20.703$ dB, $SSIM = 0.55$), (A' : $PSNR = 20.254$ dB, $SSIM = 0.564$)) et (avec régularisation l_1 : (B : $PSNR = 26.62$ dB, $SSIM = 0.917$), (B' : $PSNR = 25.668$ dB, $SSIM = 0.837$); avec régularisation l_2 : (C : $PSNR = 27.63$ dB, $SSIM = 0.924$), (C' : $PSNR = 26.965$ dB, $SSIM = 0.873$)). Il est clair que la restauration est améliorée et l'ajout d'un terme de régularisation offre plus de robustesse à l'encontre du bruit.

3.7.4 Amélioration de la restauration par la descente du gradient

Dans cette section, nous présentons une approche basée sur la descente du gradient (GD : Gradient Descent), afin d'améliorer la qualité de la restauration d'images. Ici, l'amélioration de la qualité de restauration est basée sur la méthode d'optimisation donnée par l'équation (3.13). Pour l'initialisation de l'approche itérative GD, nous utilisons l'image restaurée par l'algorithme Stack-TV.

La figure 3.11 montre l'impact important du schéma proposé sur l'amélioration de la qualité de l'image restaurée dans le cas bruité. Cette amélioration est principalement due à l'algorithme Stack-TV (norme ℓ_2) qui améliore la qualité de restauration de manière

3.7. RÉSULTATS ET DISCUSSION

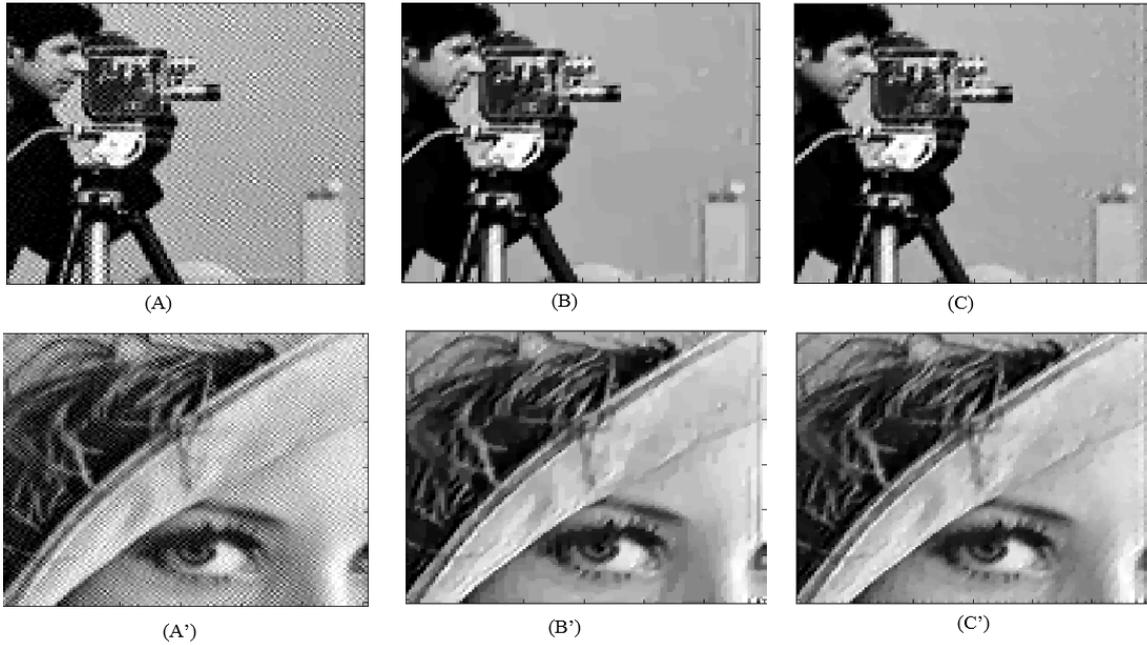


FIGURE 3.10 – (A, A') : Images restaurées sans régularisation, (B, B') : Images restaurées avec régularisation ℓ_1 , (C, C') : Images restaurées avec régularisation ℓ_2 .

considérable (Cameraman : (A : $PSNR = 27.63$ dB, $SSIM = 0.924$), Lena : (A' : $PSNR = 26.965$ dB, $SSIM = 0.873$)). L'algorithme GD offre aussi plus de performance en améliorant la qualité de restauration (Cameraman : (B : $PSNR = 28.57$ dB, $SSIM = 0.943$), Lena : (B' : $PSNR = 28.274$ dB, $SSIM = 0.907$)) avec un gain de (+**2.05%**) sur 24 itérations et de (+**3.89%**) sur 9 itérations.



FIGURE 3.11 – Résultats d'amélioration de la qualité de restauration avec l'approche proposée, (A, B) : Stack-TV ℓ_2 , (A', B') : Descente du gradient.

3.7.5 Étude comparative des algorithmes Stack-TV et ADMM-TV

Dans cette section, nous comparons les performances de notre méthode améliorée Stack-TV à la méthode existante ADMM-TV (Jiao et al., 2016). Les deux algorithmes ont été implémentés sous Matlab-*R2013b*. Le tableau 3.4 compare les résultats des méthodes proposées (Stack-TV(ℓ_1), Stack-TV(ℓ_2) et Stack-GD). On voit que les techniques proposées sont plus efficaces en qualité de restauration par rapport à la technique ADMM-TV surtout dans le cas de l'image ‘Cameraman’ corrompue par un bruit Gaussien ($SNR = 25$ dB). Néanmoins, pour le cas de l'image ‘Lena’ avec un bruit plus intense ($SNR = 20$ dB), le meilleur résultat est atteint avec la méthode Stack-GD.

TABLE 3.4 – Comparaison des performances des algorithmes Stack, Stack-TV(ℓ_1), Stack-TV(ℓ_2) et Stack-GD.

	Cameraman		Lena	
	PSNR	SSIM	PSNR	SSIM
Stack	20.703	0.55	20.254	0.564
Stack-TV (ℓ_1)	26.62	0.917	25.668	0.837
Stack-TV (ℓ_2)	27.63	0.924	26.965	0.873
Stack-GD	28.57	0.943	28.271	0.907
ADMM-TV	25.94	0.913	27.38	0.894

3.7.6 Restauration d’images dans un contexte mono-canal (cas bruité)

Dans cette section, nous étudions les performances de notre algorithme Stack-TV de restauration dans un système mono-canal (SISO). Le manque de diversité dans le cas mono-canal rend notre algorithme R-SCR inadéquat pour l’identification des filtres dégradants. Pour cette raison, nous considérons pour l’estimation les fonctions de dégradation exactes. La dégradation des images originales (‘Cameraman’ et ‘Lena’) est réalisée par un flou Gaussien ($\sigma = 1.5$) et ensuite, corrompu par deux bruits gaussiens avec un

3.8. CONCLUSION

$SNR = \{20, 25\}$ dB.

La figure 3.12 présente les résultats de la restauration dans le cas mono-canal, à l'aide de notre algorithme Stack sans régularisation (Cameraman : (A : $PSNR = 9.794$ dB, $SSIM = 0.3375$), Lena : (B : $PSNR = 9.148$ dB, $SSIM = 0.1981$)), comparés au cas multi-canal sans régularisation (Cameraman : (A' : $PSNR = 20.703$ dB, $SSIM = 0.55$), Lena : (B' : $PSNR = 20.254$ dB, $SSIM = 0.564$)). Les résultats obtenus dans le cas mono-canal montrent une restauration insuffisante qui est due à l'effet très important du bruit et aussi au mauvais conditionnement de la matrice \mathbf{H} . Nous avons pu améliorer cette restauration dans le cas multi-canal comme le montre les figures 3.12-A',B'.

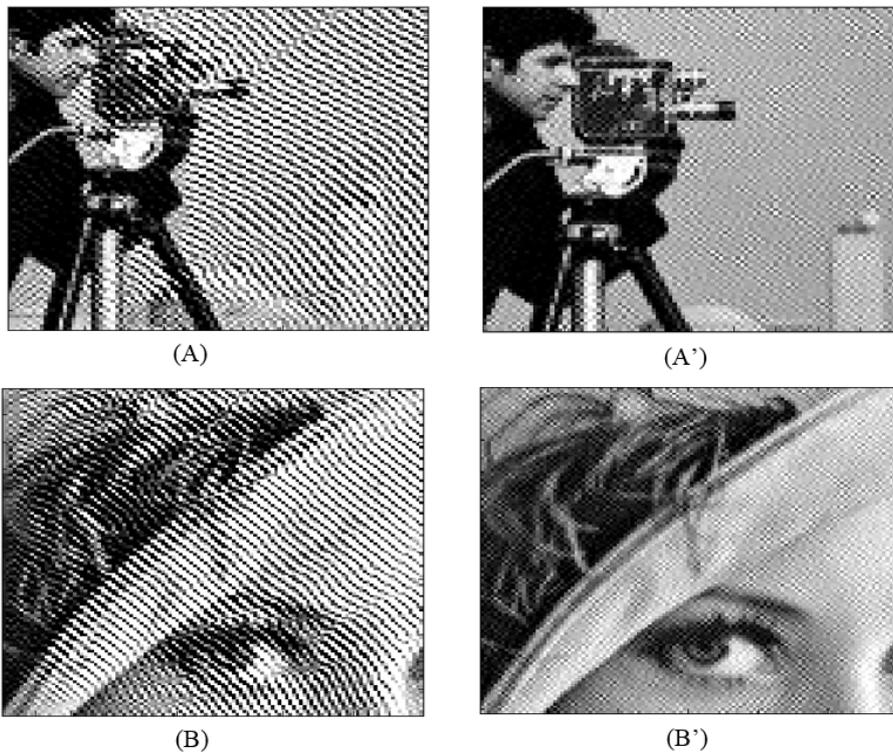


FIGURE 3.12 – (A, B) : Résultat de la restauration mono-canal (sans régularisation), (A', B') : Restauration multi-canal (sans régularisation).

3.8 Conclusion

Ce chapitre a été consacré à une nouvelle technique de restauration d'images dans un contexte multi-canal. Cette technique a été inspirée de la déconvolution par maximum de vraisemblance dans les systèmes de communication. Elle est basée sur le décodeur sé-

quentiel Stack. Tout d'abord, pour réduire le coût de calcul deux versions améliorées de l'algorithme Stack ont été considérées. La première basée sur l'exploitation de la structure à bande limitée de la matrice de filtrage \mathbf{H} et la deuxième est une technique de restauration à deux étapes (hiérarchique). De plus, pour tenir compte de l'effet du bruit additif, un terme de régularisation approprié a été ajouté au critère global à minimiser (Stack-TV). Ensuite, nous avons utilisé un algorithme de minimisation 'All-at-once' basé sur la méthode de la descente du gradient pour raffiner le résultat initialement obtenu par l'algorithme Stack-TV et améliorer globalement la qualité de restauration. Enfin, Les évaluations numériques révèlent la performance en restauration d'images de la méthode proposée, la réduction significative des coûts de calcul grâce aux modifications apportées à l'algorithme Stack-TV et son potentiel prometteur pour améliorer davantage les techniques existantes.

Chapitre 4

Restauration d'images avec critères orientés qualité

Sommaire

4.1	Introduction	78
4.2	Notations et formulation du problème	79
4.2.1	Modèle de dégradation et de restauration de l'image	80
4.2.2	Cadre général de l'algorithme ADMM	81
4.3	Métriques d'évaluation de la qualité d'images	83
4.3.1	Description de l'indice de SIMilarité Structurale (SSIM)	84
4.4	Algorithme proposé pour la restauration d'image avec critère orienté qualité	86
4.4.1	Optimisation par descente du gradient	86
4.4.2	Description du critère basé sur les mesures de qualité	87
4.5	Résultats et discussion	88
4.5.1	Performance de la restauration avec la minimisation du critère basé qualité	89
4.5.2	Impact d'utilisation de l'indice SSIM	90
4.6	Conclusion	95

4.1 Introduction

Depuis l'apparition des images numériques, les techniques de traitement d'image sont de plus en plus demandées et attirent beaucoup d'attention en raison de leur potentiel d'application. Toutefois, ces techniques comme la compression, la quantification, le tatouage (Li et al., 2011) et le débruitage (Zhang et al., 2011) impliquent la modification de la nature de ces images afin d'améliorer leurs contenus. Ce qui permet d'assurer l'interprétation humaine et les rends plus appropriées à la perception automatique de la machine (McAndrew, 2004).

Néanmoins, ces techniques affectent souvent la qualité perceptuelle de l'image. Cette dernière est rarement parfaite et les images enregistrées sont sujettes à des distorsions et des imperfections le long de la chaîne d'acquisition, de transmission, de codage/décodage et de reproduction. Pour maintenir, contrôler et améliorer la qualité des images, il est important que tous les systèmes qui génèrent ces défauts soient aussi capables d'identifier et de quantifier ces dégradations.

D'autre part, dans les années récentes, il y a eu un besoin croissant des algorithmes dédiés à l'évaluation de la qualité d'images (IQA : Image Quality Assessment). Ces algorithmes sont précis, faciles à implémenter et jouent un rôle très important dans de nombreuses applications réelles, y compris la restauration d'image, la communication, l'impression, l'affichage, la segmentation et la fusion (Wang and Bovik, 2006). Le rôle principal de ces techniques consiste généralement à quantifier l'impact des dégradations sur la qualité et à l'utiliser pour évaluer et/ou comparer les performances des systèmes de traitement.

Fondamentalement, les techniques IQA existantes peuvent être divisées en méthodes subjectives et objectives. Les méthodes subjectives impliquent des êtres humains pour évaluer la qualité des images alors que les méthodes objectives calculent automatiquement la qualité de l'image. Ces dernières peuvent être classées selon les informations disponibles en (Liu et al., 2012) :

- i) Techniques à référence complète (FR-IQA : Full Reference) où la qualité est estimée à l'aide de l'image originale et de sa version dégradée,
- ii) Techniques à référence réduite (RR-IQA : Reduced Reference) où seules certaines

informations de l'image originale sont utilisées,

- iii) Techniques sans référence ou aveugle (NR-IQA : No Reference) où seule l'image dégradée est exploitée.

Initialement, les mesures de la qualité de l'image font référence à la traditionnelle erreur moyenne absolue (MAE : Mean Absolute Error), à l'erreur quadratique moyenne (MSE : Mean Square Error), au rapport signal/bruit (SNR : Signal to Noise Ratio) et au PSNR (Peak SNR) (Eskicioglu and Fisher, 1995). Plus tard, les auteurs de (Wang et al., 2004) ont proposé une nouvelle approche nommée indice de similarité structurelle (SSIM : Structural SIMilarity index). Cette approche est inspirée du système visuel humain (HVS : Human Visual System) et bien adaptée à l'information hautement structurée des scènes naturelles.

Dans ce chapitre, notre contribution consiste à considérer l'indice SSIM non seulement pour évaluer et comparer les résultats de la restauration d'image, mais aussi comme une fonction objective utilisée potentiellement pour améliorer la qualité de la restauration. Ceci rends la fonction coût résultante de la restauration d'image hautement non linéaire. Comme première étape, la méthode des directions alternées des multiplicateurs (ADMM : Alternating Direction Method of Multipliers) est sollicitée dans ce cas de figure comme étant efficace pour initialiser ce problème d'optimisation. En effet, l'algorithme ADMM divise le problème inverse en petits fragments, ce qui entraîne sa décomposition (Jiao et al., 2016) et contribue ainsi la convergence de l'algorithme.

Comme seconde étape, la mesure de la qualité choisie (SSIM) est introduite dans la fonction coût. Le critère résultant est alors minimisé à l'aide de la descente du gradient (également appelée technique de la forte descente) (Andrei, 2004), pour une optimisation directe (raffinement) du vecteur global de paramètres.

4.2 Notations et formulation du problème

Comme détaillé ci-dessus, la restauration d'images affectées par un flou et/ou par un bruit à différents niveaux, est une application qui a souvent recours à l'IQA. Le but de la restauration d'image est d'atténuer, compenser et supprimer ces défauts qui dégradent

l'image.

4.2.1 Modèle de dégradation et de restauration de l'image

Les tâches de restauration d'image peuvent souvent être formulées comme un problème inverse linéaire mal-posé. Pour un système SISO et dans le domaine spatial, l'image observée est mathématiquement modélisée comme suit :

$$\begin{aligned} \mathbf{g}(m, n) &= \mathbf{h}(m, n) \star \mathbf{f}(m, n) + \mathbf{w}(m, n) \\ &= \sum_{i=0}^{m_h-1} \sum_{j=0}^{n_h-1} h(i, j) f(m-i, n-j) + w(m, n) \end{aligned} \quad (4.1)$$

pour chaque pixel $(m, n) : m = 1, \dots, m_g$ et $n = 1, \dots, n_g$. \mathbf{f} ($m_f \times n_f$) indique l'image originale, \mathbf{g} ($m_g \times n_g$) désigne l'image observée et \mathbf{w} ($m_w \times n_w$) est un bruit additif.

Ce modèle peut être exprimé sous forme d'un produit matrice/vecteur, comme suit :

$$\mathbf{g} = \mathbf{H} \mathbf{f} + \mathbf{w} \quad (4.2)$$

où \mathbf{H} désigne la matrice de filtrage Toeplitz par blocs associée au filtre dégradant \mathbf{h} ($m_h \times n_h$), exprimée par :

$$\mathbf{H} = \begin{bmatrix} \mathbf{H}(0) & \cdots & \mathbf{H}(m_h - 1) & & 0 \\ & \ddots & & \ddots & \\ 0 & & \mathbf{H}(0) & \cdots & \mathbf{H}(m_h - 1) \end{bmatrix}$$

avec

$$\mathbf{H}(n) = \begin{bmatrix} \mathbf{h}(n, 0) & \cdots & \mathbf{h}(n, n_h - 1) & & 0 \\ & \ddots & & \ddots & \\ 0 & & \mathbf{h}(n, 0) & \cdots & \mathbf{h}(n, n_h - 1) \end{bmatrix}$$

L'objectif principal de la restauration d'images est de trouver l'estimée de l'image idéale $\hat{\mathbf{f}}$ de telle sorte qu'elle soit la plus proche possible de l'originale \mathbf{f} . Ceci est effectué uniquement à partir des observations dégradées (floues et/ou bruitées) selon l'équation (4.2).

Dans le cas où nous supposons que le bruit additif est blanc Gaussien, la restauration de \mathbf{f} est effectuée par le biais d'une résolution d'un problème de minimisation au sens des moindres carrés, exprimé par :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in \mathbb{R}} \|\mathbf{g} - \mathbf{H} \mathbf{f}\|_2^2 \quad (4.3)$$

où $\|\cdot\|_2$ signifie la norme l_2 .

La section suivante décrit et détaille le fonctionnement de l'algorithme ADMM utilisé comme étant une méthode efficace pour l'initialisation de notre problème d'optimisation.

4.2.2 Cadre général de l'algorithme ADMM

Initialement, l'algorithme ADMM qui est une technique itérative, a été proposé pour résoudre le problème de minimisation (problème inverse linéaire) mentionné ci-dessus (équation (4.3)). Ceci est effectué à l'aide d'une régularisation de type variation totale (TV) qui a souvent prouvé ses avantages dans de nombreuses applications.

En effet, même pour des valeurs faibles du rapport signal/bruit (SNR), l'efficacité de la régularisation type TV est à nuancer pour préserver simultanément les bords tout en lissant le bruit dans les régions homogènes. Par conséquent, nous avons opté dans cette partie de travail pour l'algorithme ADMM basé sur la régularisation TV (appelé ADMM-TV) (Fan et al., 2015).

Pour restaurer approximativement l'image \mathbf{f} , la méthode variationnelle régularisée consiste à résoudre le problème de minimisation suivant :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f} \in \mathbb{R}} \|\mathbf{g} - \mathbf{H} \mathbf{f}\|_2^2 + \alpha \Psi(\nabla \mathbf{f}) \quad (4.4)$$

La fonction convexe Ψ choisie est définie comme suit (Jiao et al., 2016) :

$$\Psi(\cdot) = \|\cdot\|_{l_1} + \frac{\nu}{2} \|\cdot\|_{l_2}^2$$

avec $\nu = 1e - 3$ une constante fixée par les auteurs et ∇ est l'opérateur gradient discret

exprimé par :

$$\nabla \mathbf{f} = (\nabla_1 \mathbf{f}, \nabla_2 \mathbf{f}) \quad (4.5)$$

où pour chaque pixel (i, j) :

$$\begin{cases} \nabla_1 \mathbf{f}(i, j) = \mathbf{f}(i+1, j) - \mathbf{f}(i, j), & i = 1, \dots, m_f - 1 \\ & j = 1, \dots, n_f \\ \nabla_1 \mathbf{f}(m_f, j) = \mathbf{f}(1, j) - \mathbf{f}(m_f, j), & j = 1, \dots, n_f \end{cases}$$

$$\begin{cases} \nabla_2 \mathbf{f}(i, j) = \mathbf{f}(i, j+1) - \mathbf{f}(i, j), & i = 1, \dots, m_f \\ & j = 1, \dots, n_f - 1 \\ \nabla_2 \mathbf{f}(i, n_f) = \mathbf{f}(i, 1) - \mathbf{f}(i, n_f), & i = 1, \dots, m_f \end{cases}$$

α est un paramètre de régularisation dont le choix affecte de manière cruciale la performance de la méthode.

Tout d'abord, nous introduisons une variable supplémentaire $\mathbf{z} = \nabla \mathbf{f}$. Ainsi, l'équation (4.4) peut être reformulée dans un problème contraint comme suit :

$$\begin{cases} \text{minimiser} & \Psi(\mathbf{z}) \\ \text{subject à :} & \mathbf{g} = \mathbf{H} \mathbf{f}, \mathbf{z} = \nabla \mathbf{f} \end{cases} \quad (4.6)$$

Par la suite, le problème est partitionné en utilisant un opérateur de division variable afin de transformer le problème contraint (équation(4.6)) en plusieurs problèmes sans contraintes :

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f}, \mathbf{z} \in \mathbb{R}} \Psi(\mathbf{z}) + \frac{\rho_1}{2} \|\mathbf{g} - \mathbf{H} \mathbf{f}\|_2^2 + \frac{\rho_2}{2} \|\mathbf{z} - \nabla \mathbf{f}\|_2^2 \quad (4.7)$$

L'équation obtenue (4.7) est résolue par l'ADMM et la fonction Lagrangienne augmentée correspondante est donnée par :

$$\begin{aligned} \mathcal{L}_{\rho_1, \rho_2}(\mathbf{f}, \mathbf{z}; \boldsymbol{\lambda}_1, \boldsymbol{\lambda}_2) = & \Psi(\mathbf{z}) + \frac{\rho_1}{2} \|\mathbf{g} - \mathbf{H} \mathbf{f}\|_2^2 + \langle \boldsymbol{\lambda}_1, \mathbf{g} - \mathbf{H} \mathbf{f} \rangle + \\ & + \frac{\rho_2}{2} \|\mathbf{z} - \nabla \mathbf{f}\|_2^2 + \langle \boldsymbol{\lambda}_2, \mathbf{z} - \nabla \mathbf{f} \rangle \end{aligned} \quad (4.8)$$

où les constantes positives $\boldsymbol{\lambda}_1$ et $\boldsymbol{\lambda}_2$ sont deux multiplicateurs de Lagrange permettant

d'éviter que les deux paramètres de pénalité ρ_1 et ρ_2 convergent vers l'infini.

Finalement, nous pouvons exprimer le problème de minimisation comme suit :

$$\begin{cases} \mathbf{f}^{k+1} \in \arg \min_{\mathbf{f}} \mathcal{L}_{\rho_1, \rho_2}(\mathbf{f}, \mathbf{z}^k; \boldsymbol{\lambda}_1^k, \boldsymbol{\lambda}_2^k) \\ \mathbf{z}^{k+1} \in \arg \min_{\mathbf{z}} \mathcal{L}_{\rho_1, \rho_2}(\mathbf{f}^{k+1}, \mathbf{z}; \boldsymbol{\lambda}_1^k, \boldsymbol{\lambda}_2^k) \\ \boldsymbol{\lambda}_1^{k+1} = \boldsymbol{\lambda}_1^k + \rho_1(\mathbf{H} \mathbf{f}^{k+1} - \mathbf{g}) \\ \boldsymbol{\lambda}_2^{k+1} = \boldsymbol{\lambda}_2^k + \rho_2(\nabla \mathbf{f}^{k+1} - \mathbf{z}^{k+1}) \end{cases} \quad (4.9)$$

Cette formulation respecte une minimisation alternée. Tout d'abord, nous commençons par résoudre la minimisation du sous problème lié à la variable \mathbf{f} . Ensuite, nous continuons par la minimisation du sous problème lié à \mathbf{z} . Finalement, les différents paramètres sont mis à jour et ceci en fonction des résultats de minimisation obtenus précédemment. Pour plus de détails, voir la référence (Jiao et al., 2016).

4.3 Métriques d'évaluation de la qualité d'images

Une métrique de qualité d'image (IQM : Image Quality Metric) est un critère mathématique objectif permettant d'estimer la qualité des images et ceci sans avoir recours à un observateur humain. Ainsi, cette métrique joue un rôle très crucial dans le développement de système de traitement d'images et de vidéos. Dans la littérature, nous trouvons de nombreuses métriques IQM qui ont été proposées et développées. Un résumé succinct de plus de 100 métriques a été donné dans (Pedersen and Hardeberg, 2009).

Dans notre travail, nous nous sommes concentrés sur les métriques IQM à référence complète (FR-IQM), qui représentent la grande majorité des algorithmes IQA, où l'image originale (image de référence) et les images dégradées sont utilisées dans l'estimation de la qualité. Ces métriques à référence complète sont basées sur différents critères (Chandler, 2013), tels que :

- Les modèles de système visuel humain (HVS),
- Les statistiques de l'image et/ou l'apprentissage machine,

- Les différents espaces couleurs,
- La segmentation d'image et/ou analyse par région,
- La structure d'image (méthodes basées sur le gradient et l'indice SSIM).

4.3.1 Description de l'indice de SIMilarité Structurale (SSIM)

Brièvement, l'indice SSIM est une mesure de similarité entre deux images numériques. Comme décrit dans (Wang et al., 2004), le SSIM suppose que les images naturelles sont fortement structurées et que le système visuel humain est très sensible aux distorsions structurelles. L'information structurelle dans une image est définie comme étant des attributs qui représentent la structure des objets dans la scène, indépendamment de la luminance et du contraste (Wang et al., 2004).

La forme la plus générale de la mesure SSIM entre l'image originale \mathbf{f} et sa version restaurée \mathbf{g} , est :

$$SSIM(\mathbf{f}, \mathbf{g}) = [L(\mathbf{f}, \mathbf{g})]^{\theta_1} [C(\mathbf{f}, \mathbf{g})]^{\theta_2} [S(\mathbf{f}, \mathbf{g})]^{\theta_3} \quad (4.10)$$

où les pondérations θ_1 , θ_2 et θ_3 sont des constantes positives utilisées pour ajuster l'importance relative des trois composantes (L, C, S).

La métrique SSIM modélise la distorsion/similarité entre l'image originale \mathbf{f} et sa version dégradée \mathbf{g} comme étant trois composantes complémentaires (Figure 4.1), à savoir la similarité de luminance, $L(\mathbf{f}, \mathbf{g})$, la similarité du contraste, $C(\mathbf{f}, \mathbf{g})$ et la similarité structurelle, $S(\mathbf{f}, \mathbf{g})$, décrits mathématiquement comme suit :

$$L(\mathbf{f}, \mathbf{g}) = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \quad (4.11)$$

$$C(\mathbf{f}, \mathbf{g}) = \frac{2\sigma_f\sigma_g + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (4.12)$$

$$S(\mathbf{f}, \mathbf{g}) = \frac{\sigma_{fg} + C_3}{\sigma_f\sigma_g + C_3} \quad (4.13)$$

où μ_f , μ_g , σ_f^2 , σ_g^2 et σ_{fg} sont la moyenne de \mathbf{f} , la moyenne de \mathbf{g} , la variance de \mathbf{f} , la variance de \mathbf{g} et la covariance de \mathbf{f} et \mathbf{g} , respectivement.

4.3. MÉTRIQUES D'ÉVALUATION DE LA QUALITÉ D'IMAGES

Les constantes C_1 , C_2 et C_3 sont choisies de manière à stabiliser la mesure de distorsion pour de faibles moyennes et variances.

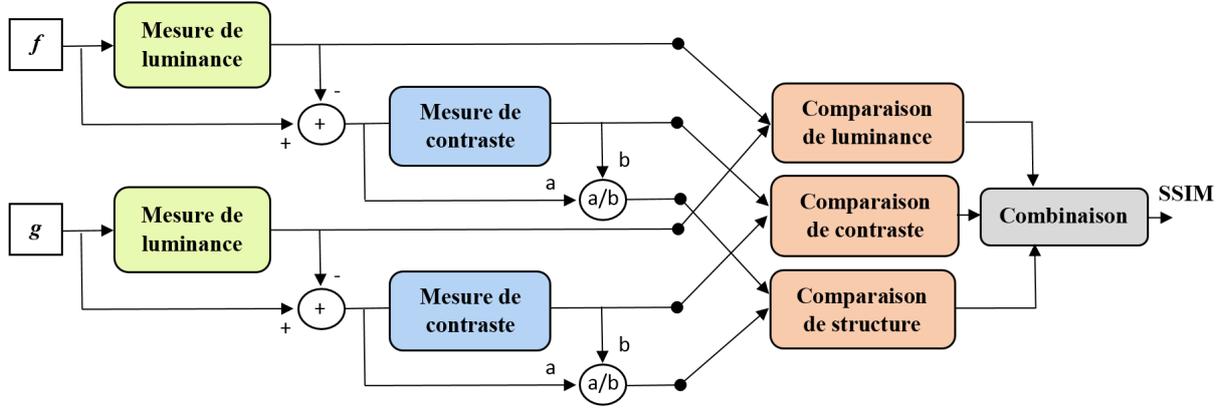


FIGURE 4.1 – Système de mesure de l'indice SSIM (Wang et al., 2005).

La métrique SSIM est calculée avec une fenêtre coulissante avec un certain chevauchement (généralement la taille de la fenêtre est fixée à 11×11). Par ce biais, il est possible d'obtenir une carte de distorsion/similarité.

La qualité globale de l'image est obtenue par la moyenne des valeurs calculées localement :

$$SSIM(\mathbf{f}, \mathbf{g}) = \frac{1}{m_g \times n_g} \sum_{m=1}^{m_g} \sum_{n=1}^{n_g} SSIM_{fg}(m, n) \quad (4.14)$$

Dans ce travail, nous allons utiliser la formulation simplifiée de l'indice SSIM qui a été proposée dans (Channappayya et al., 2008b). Avec $\theta_1 = \theta_2 = \theta_3 = 1$ et $C_3 = C_2/2$ nous obtenons l'expression suivante :

$$SSIM(\mathbf{f}, \mathbf{g}) = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \times \frac{2\sigma_{fg} + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (4.15)$$

où C_1 et C_2 sont définis comme suit :

$$\begin{aligned} C_1 &= (K_1 \times L)^2 \\ C_2 &= (K_2 \times L)^2 \end{aligned} \quad (4.16)$$

avec L la dynamique des valeurs des pixels (soit $L = 255$ pour des images codées sur 8 bits) et les constantes K_1 et K_2 fixées à 0.01 et 0.03, respectivement.

A noter que, l'indice SSIM est symétrique $SSIM(\mathbf{f}, \mathbf{g}) = SSIM(\mathbf{g}, \mathbf{f})$ et prend ses

valeurs entre $0 \leq SSIM(\mathbf{f}, \mathbf{g}) \leq 1$, atteignant 1 lorsque la restauration est parfaite c.à.d $\mathbf{f} = \mathbf{g}$.

4.4 Algorithme proposé pour la restauration d'image avec critère orienté qualité

Les travaux de (Boudjenouia et al., 2016a) ont introduit une nouvelle approche ‘*All-at-one*’ simple et efficace pour les problèmes d’optimisation dans le domaine du traitement d’images afin d’améliorer la qualité de la restauration.

En utilisant cette approche, notre objectif est d’étudier si un critère basé sur la qualité peut contribuer à améliorer la restauration d’images. Ainsi, pour tenter de répondre à cette question, nous proposons d’intégrer une mesure de qualité comme terme supplémentaire dans la fonction coût à minimiser de l’équation (4.4).

Le processus d’optimisation de ce critère résultant s’effectue en utilisant un algorithme de descente de gradient et ceci après une étape d’initialisation à l’aide de la méthode ADMM-TV, décrite précédemment.

4.4.1 Optimisation par descente du gradient

Notre choix basé sur la technique de descente du gradient est justifié par le fait que cette méthode est connue pour les problèmes d’optimisation à très grande échelle. La méthode est facile à mettre en œuvre et chaque itération est relativement peu coûteuse (Duy, 2009).

La descente du gradient est une méthode itérative qui requiert un point d’initialisation, fixé dans notre cas par le résultat optimal de l’algorithme ADMM-TV. Par la suite, la convergence vers la solution désirée est assurée en suivant le gradient négatif.

La formule standard pour une telle méthode d’optimisation est donnée par la dérivation suivante :

$$\mathbf{f}^{k+1} = \mathbf{f}^k - \xi \nabla Q(\mathbf{f}^k) \quad (4.17)$$

où ∇ est le gradient discret, ξ est un paramètre non négatif choisi 'assez petit' pour garantir la propriété de descente du critère (Andrei, 2004) et \mathbf{f}^k désigne l'image restaurée à l'itération k .

À l'itération $k = 0$, l'algorithme de descente du gradient est initialisé par l'image restaurée, résultat de la méthode ADMM-TV. $Q(\mathbf{f})$ est une fonction différentiable qui décrit la forme proposée pour le critère basé sur les mesures de qualité.

4.4.2 Description du critère basé sur les mesures de qualité

Dans ce travail, pour le choix du critère à minimiser, nous avons opté pour la forme hybride suivante :

$$Q(\mathbf{f}) = \|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2 + \beta \Psi(\nabla\mathbf{f}) + \gamma IQM(\mathbf{g}, \mathbf{f}) \quad (4.18)$$

où

1. $\|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2$ reflète la somme carrée des résidus dans le but est de minimiser les différences existantes entre l'image dégradée et celle estimée.
2. $\Psi(\nabla\mathbf{f})$ est le terme de régulation type TV utilisé essentiellement pour préserver les plus importantes caractéristiques de l'image telles que les arêtes, les bords et les limites des objets.
3. $IQM(\mathbf{g}, \mathbf{f})$ représente la mesure de la qualité introduite dans le critère global à minimiser.
4. β et γ sont des constantes positives qui garantissent un équilibre entre les trois termes du critère. Ces constantes sont fixées de manière *ad-hoc*.

Il convient de noter que pour la mesure de qualité $IQM(\mathbf{g}, \mathbf{f})$ retenue dans ce travail est donnée par l'équation (4.19). Cette métrique est exprimée sous plusieurs formes, qui seront exploitées et détaillées dans la section suivante (Résultats et discussion).

$$IQM(\mathbf{g}, \mathbf{f}) = 1 - SSIM(\mathbf{g}, \mathbf{H}\hat{\mathbf{f}}) \quad (4.19)$$

4.5 Résultats et discussion

Dans cette section, nous présentons les résultats de simulation afin d'étudier la performance de la méthode proposée. Pour toutes les expériences, les images ont été dégradées en appliquant tout d'abord un flou sur chacune d'elles, suivi de l'ajout d'un bruit blanc gaussien.

En outre, le rapport signal/bruit de crête (PSNR) en dB exprimé par l'équation (4.20) et l'indice SSIM donné par l'équation (4.15) ont été utilisés à des fins de comparaison (Wang and Bovik, 2009).

$$PSNR = 10 \times \log \frac{255^2}{MSE} \quad [dB] \quad (4.20)$$

où MSE est l'erreur quadratique moyenne.

Pour nos simulations, deux types d'images en niveau de gris (synthétique et naturelle tirées de la base de données BCU (Chabrier et al., 2006)) ont été choisies comme vecteurs de test.

Le tableau 4.1 présente les différentes images et les types de dégradation utilisées.

TABLE 4.1 – Images dégradées utilisées pour les expériences.

Image	Taille	Flou		Bruit
		Type	σ_{Flou}	
Synthétique	(256 × 256)	Gaussien	5 (3 × 3)	3
Lena	(512 × 512)	Gaussien	5 (9 × 9)	2
Cameraman	(256 × 256)	Gaussien	15 (9 × 9)	2
Pirate	(512 × 512)	Mouvement/45 degrés	11 pixels	3

4.5.1 Performance de la restauration avec la minimisation du critère basé qualité

Dans cette section, la méthode proposée est appliquée sur toutes les images dégradées du tableau 4.1. L’algorithme de descente du gradient a été appliqué, après que l’algorithme ADMM-TV ait atteint son résultat optimal, en utilisant le critère de l’équation (4.18) avec un choix approprié des paramètres β et γ pour chaque simulation.

Tout d’abord, l’algorithme proposé a été appliqué sur des images floues (cas non bruité). Comme nous pouvons le constater sur la figure 4.2, l’algorithme ADMM-TV donne une bonne qualité de restauration. Par conséquent, l’amélioration de la qualité de restauration par descente du gradient a un impact modeste avec un gain relativement négligeable.

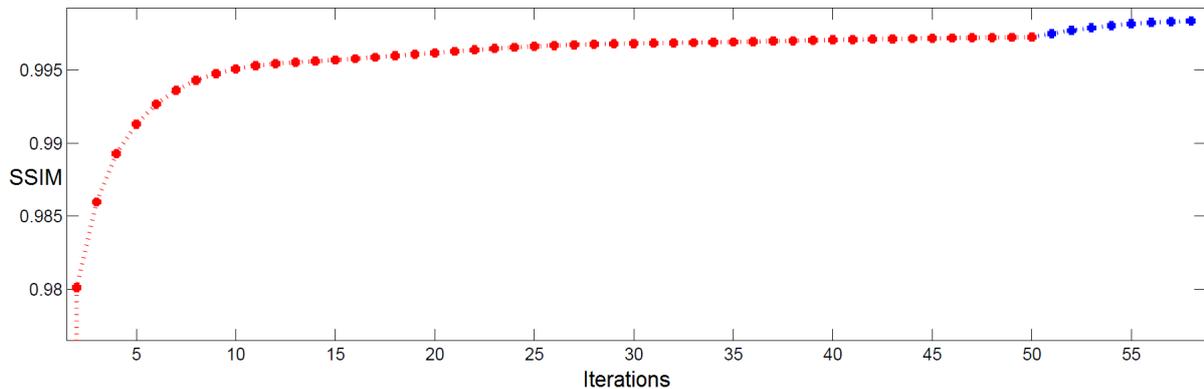


FIGURE 4.2 – Amélioration de la restauration d’image dans le cas non bruité (ADMM-TV (rouge) suivi par la descente du gradient (bleu)).

Le tableau 4.2 montre les résultats obtenus lorsqu’on ajoute un bruit blanc gaussien. On voit que l’amélioration de la qualité de restauration est plus importante¹. Ceci est principalement dû à l’algorithme de descente de gradient (voir explication détaillée dans la sous-section 5.5.2), qui offre une qualité meilleure par rapport au résultat de l’ADMM-TV.

En effet, l’algorithme de descente du gradient considéré représente une optimisation *all-at-one* (contrairement à l’optimisation alternative de la méthode ADMM), qui est connue pour fournir une bonne convergence lorsqu’elle est correctement initialisée (Acar et al., 2011).

1. Le gain d’amélioration a été calculé comme le rapport entre les résultats obtenus par l’algorithme ADMM-TV et par l’algorithme de descente du gradient.

TABLE 4.2 – Comparaison des résultats de la restauration par l’algorithme proposé avec critère qualité.

		Synthétique	Lena	Cameraman	Pirate
Image dégradée		5.73	5.75	5.58	8.84
Résultat ADMM-TV	PSNR	28.35	30.31	28.87	28.5
Descente du Gradient	[dB]	34.54	33.15	29.63	30.60
Gain d’amélioration %		+21.83	+9.36	+2.63	+7.36
Image dégradée		0.4285	0.0837	0.0839	0.2042
Résultat ADMM-TV	SSIM	0.6480	0.7239	0.7140	0.7091
Descente du Gradient		0.8813	0.9135	0.8825	0.8550
Gain d’amélioration %		+36.00	+26.19	+23.59	+20.57
Nombre d’itérations		12	20	14	23

Les figures 4.3 et 4.4 montrent les résultats de la restauration en appliquant l’algorithme proposé sur des images de différentes natures ‘Synthétique’ et ‘Pirate’.

4.5.2 Impact d’utilisation de l’indice SSIM

Pour étudier l’effet réel de l’utilisation de la mesure de qualité (indice SSIM) dans le critère global, plusieurs tests basés sur les différentes formes de la mesure SSIM sont explorées dans cette section :

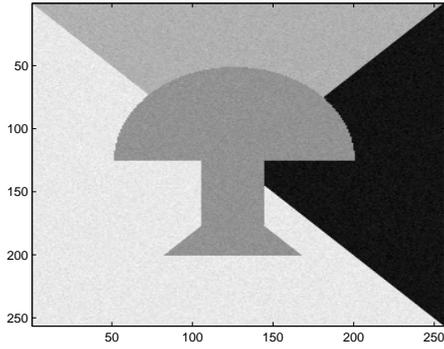
- SSIM **sans** information *a priori* sur l’image de référence,
- SSIM **avec** information *a priori* sur l’image de référence.

Dans le premier cas (sans information *a priori*), la restauration a été réalisée sans aucune information préalable sur l’image originale \mathbf{f} . La mesure SSIM a été utilisée sous sa forme simplifiée donnée par l’équation (4.15) et ceci en comparant l’image dégradée \mathbf{g} au résultat estimé $\mathbf{H}\hat{\mathbf{f}}$, comme suit :

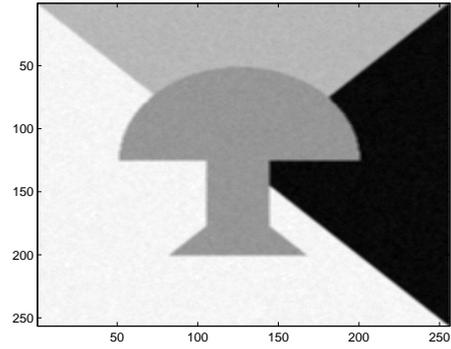
$$IQM(\mathbf{g}, \mathbf{f}) = 1 - SSIM(\mathbf{g}, \mathbf{H}\hat{\mathbf{f}}) \quad (4.21)$$

Comme le montre le tableau 4.3 et la figure 4.5, les résultats obtenus indiquent que le gain d’amélioration ne dépasse pas **1.25%**. Étant donné que l’indice SSIM représente une

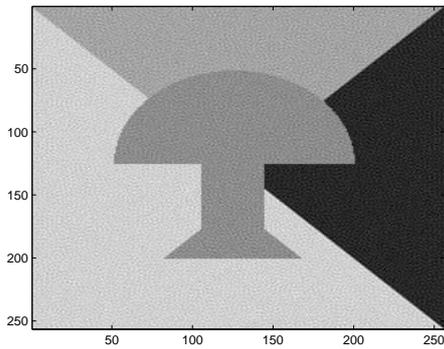
4.5. RÉSULTATS ET DISCUSSION



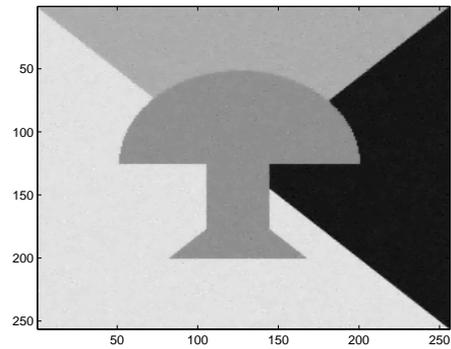
(a) Image originale synthétique



(b) Image dégradée



(c) Restauration par ADMM-TV



(d) Amélioration par la descente du gradient

FIGURE 4.3 – Résultat de la restauration de l'image ‘synthétique’ par l’algorithme proposé (avec critère qualité).

valeur de qualité moyenne sur l’ensemble de l’image (mesure **globale** de qualité), nous avons également testé une version modifiée qui met en évidence la mesure **locale** de la qualité d’image (carte de qualité).

TABLE 4.3 – Amélioration de la qualité avec utilisation du SSIM sans information *a priori* (mesure **globale** de qualité).

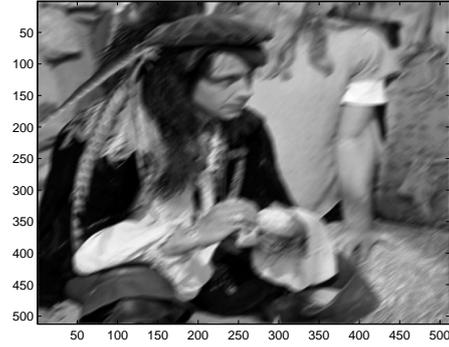
	Synthétique	Lena	Cameraman	Pirate
SSIM ($\gamma = 0$)	0.8705	0.9054	0.8681	0.8447
SSIM (γ optimal)	0.8804	0.9129	0.8790	0.8532
Gain IQ (%)	+1.14	+0.83	+1.25	+1.01

La formulation de la mesure locale SSIM est donnée comme suit :

$$IQM(\mathbf{g}, \mathbf{f}) = \sum_{i=1}^{m_f n_f} (1 - SSIM_L(\mathbf{g}_i, \mathbf{H} \hat{\mathbf{f}}_i)) \quad (4.22)$$



(a) Pirate originale



(b) Image dégradée



(c) Restauration par ADMM-TV



(d) Amélioration par la descente du gradient

FIGURE 4.4 – Résultat de la restauration de l'image ‘Pirate’ par l’algorithme proposé (avec critère qualité).

où $SSIM_L$ représente la carte d’indice SSIM qui fournit une mesure locale de la qualité d’image sur chaque pixel (en utilisant une fenêtre coulissante de taille (11×11)). Cette métrique locale est donc utilisée comme une pseudo-distance dans le processus d’optimisation.

Le tableau 4.4 et la figure 4.6 présentent les résultats de restauration. Malheureusement, ces résultats sont similaires (c’est-à-dire avec un faible gain) à ceux du tableau 4.3. Il s’agit ici d’un problème de **Overfitting**².

Par conséquent, l’algorithme proposé tente d’approximer le résultat estimé \hat{f} à l’image dégradée g au lieu d’estimer le \hat{f} le plus proche de l’image originale f qui est l’objectif principal.

Dans le deuxième cas (avec information *a priori*), nous montrons dans la suite, com-

2. Nous avons observé que le gain est plus élevé lorsque nous utilisons l’image exacte au lieu de celle estimée.

4.5. RÉSULTATS ET DISCUSSION



(a) Lina originale



(b) Image dégradée



(c) Restauration par ADMM-TV



(d) Amélioration par la descente du gradient

FIGURE 4.5 – Résultat de la restauration sans information *a priori* (Mesure **globale** de qualité).

TABLE 4.4 – Amélioration de la qualité avec utilisation du SSIM sans information *a priori* (mesure **locale** de qualité).

	Synthétique	Lena	Cameraman	Pirate
SSIM ($\gamma = 0$)	0.8705	0.9054	0.8681	0.8447
SSIM (Optimal γ)	0.8813	0.9135	0.8825	0.8550
Gain IQ (%)	+1.24	+0.89	+1.65	+1.21

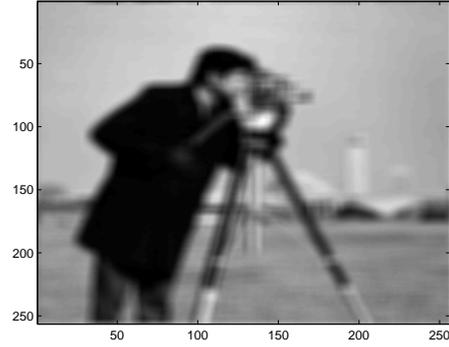
ment réaliser un gain significatif dans l'amélioration de la qualité de restauration. Ceci, en utilisant l'image originale \mathbf{f} comme référence pour calculer la mesure de qualité SSIM, comme suit :

$$IQM(\mathbf{f}, \hat{\mathbf{f}}) = \sum_{i=1}^{m_f n_f} (1 - SSIM_L(\mathbf{f}_i, \hat{\mathbf{f}}_i)) \quad (4.23)$$

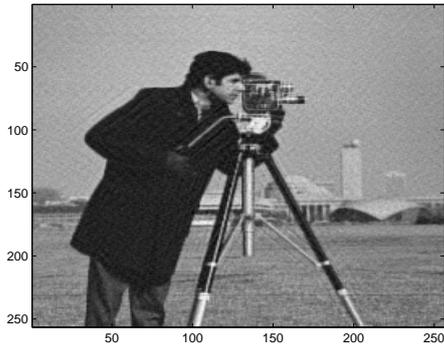
Le tableau 4.5 montre et prouve que l'algorithme proposé est plus performant (avec un gain de **+20.98 %**) dans le processus de restauration, lorsque l'information *a priori*



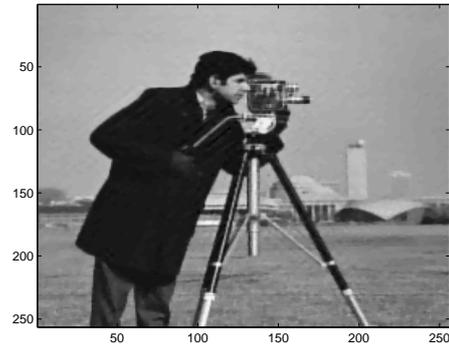
(a) Cameraman originale



(b) Image dégradée



(c) Restauration par ADMM-TV



(d) Amélioration par la descente du gradient

FIGURE 4.6 – Résultat de la restauration sans information *a priori* (Mesure **locale** de qualité).

est complètement intégrée dans la mesure de qualité (SSIM).

TABLE 4.5 – Résultats de la restauration avec intégration complète d'information *a priori*.

Paramètre γ	1e+2	1e+3	1e+4	1e+5
Gain d'amélioration (%)	+1.98	+6.11	+20.98	+14.69

Comme nous l'avons vu dans les deux situations extrêmes (tout ou rien) mentionnées précédemment, la quantité d'information *a priori* sur l'image originale joue un rôle essentiel dans l'amélioration de la qualité de restauration. Ainsi, nous faisons une conjecture sur la base des informations *a priori* **partielles** (structurelles ou statistiques) de l'image originale, qu'une amélioration non négligeable de la restauration peut être atteinte.

4.6 Conclusion

Dans ce chapitre, une nouvelle méthode de restauration d'images basée sur l'exploitation des avantages dérivant des mesures de la qualité d'image a été présentée. Cette métrique n'est pas seulement utilisée pour comparer les résultats de la restauration, mais est aussi intégrée dans le processus d'optimisation lui-même. Pour améliorer les résultats de la restauration, nous avons utilisé la technique de la descente du gradient pour affiner le résultat initial obtenu par l'algorithme ADMM-TV.

Le défi consiste à trouver un outil pour exploiter la quantité d'information *a priori*. À cette fin, différentes expériences ont été conduites, en commençant par le cas où aucune information *a priori* n'est utilisée. Comme résultat un faible pourcentage d'amélioration dans la qualité de restauration a été obtenu. Dans un second temps, l'information *a priori* est complètement intégrée dans le critère. Dans ce cas, une amélioration considérable de la qualité a été réalisée. Cela prouve que l'exploitation d'une certaine quantité d'information *a priori* peut améliorer la qualité de restauration. Cependant, cette quantité est actuellement indéfinie, ce qui reste un problème ouvert.

Les exemples de simulations donnés illustrent l'efficacité de la méthode proposée et son potentiel prometteur pour améliorer davantage les techniques de restauration d'images existantes.

Chapitre 5

Séparation aveugle d'images

Sommaire

5.1	Introduction	97
5.2	Formulation du problème de séparation d'images	98
5.3	Description des algorithmes de séparation aveugle d'images	99
5.3.1	Algorithme de séparation basé sur les statistiques du second ordre	100
5.3.2	Algorithme de séparation basé sur la représentation parcimonieuse des sources	101
5.4	Approches proposées pour la séparation aveugle d'images	104
5.4.1	Approche duale pour la séparation aveugle d'images	105
5.4.2	Approche hybride pour la séparation aveugle d'images	106
5.5	Résultats et discussion	108
5.5.1	Évaluation de la performance de l'approche duale de séparation	109
5.5.2	Séparation aveugle d'images basée sur la minimisation d'un critère hybride	112
5.5.3	Séparation aveugle d'images médicales	114
5.6	Conclusion	114

5.1 Introduction

Le concept de la séparation aveugle des sources (BSS : Blind Source Separation) peut être décrit comme suit : ‘trouver les signaux/images utiles ou originaux qui ont été mélangés, en utilisant très peu d’informations sur ces signaux et sans connaître a priori le processus de mélange’. Les signaux d’intérêt sont nommés ‘sources’ et le problème le plus connu dans ce contexte est celui de ‘Cocktail party’ utilisé pour la séparation de signaux audio. La séparation aveugle de source est un domaine de recherche très important en traitement du signal. On le trouve dans plusieurs domaines tels que l’astronomie, les communications (radar et sonar), la prospection sismique, le traitement des images médicales, la chimie analytique ainsi que dans de nombreux champs d’application (Comon and Jutten, 2010).

Au cours des deux dernières décennies, il y a eu un intérêt croissant pour la séparation aveugle des sources. Les travaux antérieurs exploitaient soit une diversité quantitative mesurable, soit le contraste des sources (par exemple, décorrélation, indépendance statistique, etc.), soit la diversité morphologique des sources et leur parcimonie.

(Jutten and Herault, 1991) ont été les premiers à s’intéresser de près à ce problème et ont réalisé une série de travaux qui ont abouti à la proposition d’une structure itérative appliquée à la séparation d’un mélange de deux signaux. Leurs travaux ont principalement exploités les statistiques de quatrième ordre. Par conséquent plusieurs méthodes ont été proposées suite à cette orientation dans laquelle ces statistiques apparaissent explicitement (Cardoso, 1989). En même temps, le problème d’identifiabilité et de séparabilité des sources a été analysé explicitement dans (Tong et al., 1991) ont utilisé des méthodes basées sur des statistiques du second ordre (Tong et al., 1993). Par la suite, la définition du problème de séparation de sources en tant qu’un problème d’analyse des composants indépendants (ICA : Independent Component Analysis) a été introduite par (Comon, 1994). Cette dernière est une extension de l’analyse des composants principales (PCA : Principal Component Analysis).

Ces derniers temps, un nouvel axe de recherche a été largement discuté pour la séparation de sources basé sur l’utilisation de la représentation parcimonieuse des signaux

sources. Dans la littérature, les travaux de (Zibulevsky and Pearlmutter, 2001) et (Bofill and Zibulevsky, 2001) ont ouvert la voie à l'exploitation de cette propriété parcimonieuse pour la BSS. À cet effet, plusieurs techniques ont été développées en utilisant la transformation en ondelettes (Bronstein et al., 2003; Ichir and Mohammad-Djafari, 2005) et aussi la projection sur des dictionnaires parcimonieux (Bofill and Zibulevsky, 2001).

Ce chapitre est dédié à l'évaluation des performances des deux techniques de BSS pour étudier comment exploiter leur complémentarité afin d'améliorer la qualité de séparation d'images. La première approche (algorithme WASOBI) est une technique basée sur l'indépendance des sources (Yeredor, 2000). La seconde est une technique de séparation (algorithme ISBS) basée sur l'exploitation d'une représentation parcimonieuse des sources (Souidene et al., 2007). Ainsi, deux concepts différents sont considérés ici pour proposer une technique composite bénéficiant des avantages de chacune de ces méthodes. Tout d'abord, nous proposons une approche 'duale' où les caractéristiques du signal sont exploitées l'une après l'autre. Ensuite, nous introduisons une approche 'hybride' basée sur une pondération appropriée des critères de décorrélation des sources et de représentation parcimonieuse. Ces deux approches sont analysées et comparées à l'aide des simulations numériques.

5.2 Formulation du problème de séparation d'images

Dans cette section, nous décrivons tout d'abord les notations de base, puis nous examinons le système proposé pour la séparation aveugle des sources.

Soit $\mathbf{f}(m, n) = [f_1(m, n), f_2(m, n), \dots, f_N(m, n)]^T$ le vecteur $N \times 1$ des sources indépendantes qui provient de N sources images f_1, f_2, \dots, f_N , chacune est de taille (m_f, n_f) . Ainsi, les mélanges observés $\mathbf{g}(m, n) = [g_1(m, n), g_2(m, n), \dots, g_M(m, n)]^T$ est un vecteur $M \times 1$ exprimé dans le cas d'un modèle de mélange instantané, comme suit :

$$\mathbf{g}(m, n) = \mathbf{A}\mathbf{f}(m, n) + \mathbf{w}(m, n) \quad (5.1)$$

où \mathbf{A} est la matrice $M \times N$ de mélange de rang (colonne) plein ($M \geq N$) et $\mathbf{w}(m, n) = [w_1(m, n), w_2(m, n), \dots, w_M(m, n)]^T$ est le vecteur $M \times 1$ du bruit additif.

La tâche principale des algorithmes de séparation aveugle d'images est de récupérer les sources images à partir des mélanges \mathbf{g} , selon :

$$\hat{\mathbf{f}}(m, n) = \mathbf{B} \mathbf{g}(m, n) \quad (5.2)$$

où \mathbf{B} est la matrice de séparation $N \times M$ et $\hat{\mathbf{f}}(m, n) = [\hat{f}_1(m, n), \hat{f}_2(m, n), \dots, \hat{f}_N(m, n)]^T$ est l'estimé des N images originales.

D'après les travaux de (Belouchrani et al., 1997) et pour surpasser un certain nombre d'ambiguïtés liées au problème de la séparation aveugle, la meilleure solution est de déterminer la matrice \mathbf{B} à une permutation près et à un terme multiplicatif près. C'est-à-dire \mathbf{B} est une matrice de séparation si et seulement si :

$$\mathbf{B} \mathbf{g}(m, n) = \mathbf{P} \mathbf{\Lambda} \mathbf{f}(m, n) \quad (5.3)$$

où \mathbf{P} est une matrice de permutation et $\mathbf{\Lambda}$ est une matrice diagonale non singulière.

Pour accomplir la séparation aveugle d'images, nous supposons dans la suite de ce travail que les sources sont mutuellement décorréelées et que chacune d'elles a une représentation parcimonieuse qui sera expliquée dans la section 5.3.2.

5.3 Description des algorithmes de séparation aveugle d'images

Dans cette section, nous décrivons brièvement les algorithmes de séparation de sources qui sont considérés dans ce travail. Tout d'abord, nous commençons par l'algorithme WASOBI (Weights-Adjusted Second Order Blind Identification) développé dans (Yeredor, 2000), puis nous décrivons l'algorithme de séparation itératif parcimonieux (ISBS : Iterative Sparse Blind Separation) proposé par (Souidene et al., 2007).

5.3.1 Algorithme de séparation basé sur les statistiques du second ordre

Dans certains cas et afin de ne pas être limité par la condition d'indépendance des sources, la séparation aveugle de source peut être fondée sur des statistiques de second ordre (SOS : Second Order Statistics) qui ne nécessitent que des sources non corrélées. Ces techniques basées sur les SOS ont l'avantage d'être moins sensibles au bruit et aux valeurs aberrantes. Ainsi elles conduisent à utiliser moins de données pour l'estimation des sources. De plus, ces techniques sont souvent plus faciles à mettre en œuvre et efficaces en termes de temps de calcul (Torkkola, 1999).

Sous l'hypothèse que les sources sont centrées¹ et décorréélées, la matrice de covariance correspondante est exprimée comme suit :

$$\begin{aligned} \mathbf{R}_f[\tau] &= E[\mathbf{f}(t + \tau) \mathbf{f}^*(t)] \\ &= \text{diag}[\rho_1(\tau), \rho_2(\tau), \dots, \rho_N(\tau)] \end{aligned} \quad (5.4)$$

où $\rho_i(\tau) = E[\mathbf{f}_i(t + \tau) \mathbf{f}_i^*(t)]$ est l'auto-covariance de \mathbf{f}_i et $\text{diag}[\cdot]$ est la matrice diagonale formée par les éléments de ses arguments.

A noter ici que le vecteur \mathbf{f}_i représente la version vectorisée de la $i^{\text{ème}}$ image.

Avant de procéder à la séparation des sources, une autre étape de pré-traitement (après le centrage des signaux) est nécessaire. Cette étape correspond au blanchiment des signaux qui servent à transformer notre système en un autre caractérisé par une matrice de mélange unitaire, selon :

$$\mathbf{z} = \mathbf{W}\mathbf{y}$$

où $\mathbf{y} = \mathbf{A}\mathbf{f}$ et \mathbf{W} ($N \times M$) est la matrice de blanchiment telle que² :

$$E[\mathbf{W}\mathbf{y}\mathbf{y}^*\mathbf{W}^*] = \mathbf{W}\mathbf{R}_y(0)\mathbf{W}^* = \mathbf{W}\mathbf{A}\mathbf{A}^*\mathbf{W}^* = \mathbf{I} \quad (5.5)$$

avec $\mathbf{W}\mathbf{A} = \mathbf{U}$ une matrice unitaire de taille ($N \times N$).

1. En pratique, le centrage des sources est réalisé en utilisant un pré-traitement avant de procéder à leur séparation.

2. Pour plus de simplicité, le terme de bruit additif est négligé et nous tirons profit de l'ambiguïté d'échelle pour assumer sans perte de généralité que toutes les sources ont une variance unitaire.

Après l'étape de blanchiment, la matrice de covariance (du nouveau système \mathbf{z}) est diagonalisable en utilisant \mathbf{U} , sachant que :

$$\begin{aligned}\mathbf{R}_z[\tau] &= \mathbf{W} \mathbf{R}_g \mathbf{W}^* \\ &= \mathbf{U} \mathbf{R}_f \mathbf{U}^* \\ &= \mathbf{U} \text{diag}[\rho_1(\tau), \rho_2(\tau), \dots, \rho_N(\tau)] \mathbf{U}^*\end{aligned}\tag{5.6}$$

où \mathbf{U}^* fait référence au transposée conjuguée de la matrice \mathbf{U} .

Dans (Belouchrani et al., 1997), pour trouver la matrice \mathbf{U} , ils ont utilisé la diagonalisation conjointe (JD : Joint Diagonalization) de plusieurs matrices de covariance avec des retards différents. L'utilisation correcte de plusieurs matrices de covariance peut considérablement augmenter la robustesse de la séparation de sources.

Par la suite, dans (Yeredor, 2000), les auteurs proposent d'utiliser des pondérations en dépendance des données pour ajuster convenablement l'importance de chacune des précédentes matrices de covariance dans le critère global, JD.

Après avoir estimé la matrice \mathbf{U} , il est possible d'estimer les images sources, ainsi que la matrice de mélange, comme suit :

$$\hat{\mathbf{f}} = \hat{\mathbf{U}}^* \hat{\mathbf{W}} \mathbf{g}, \quad \hat{\mathbf{A}} = \hat{\mathbf{W}}^\# \hat{\mathbf{U}}\tag{5.7}$$

où $\hat{\mathbf{W}}^\#$ désigne le pseudo-inverse de $\hat{\mathbf{W}}$.

5.3.2 Algorithme de séparation basé sur la représentation parcimonieuse des sources

Cette section présente le deuxième algorithme ISBS, basé sur une représentation parcimonieuse des images sources. D'une manière générale, la parcimonie signifie que seul un petit nombre d'échantillons dans l'image (pixels) sont significativement différents de la valeur zéro. Dans (Souidene et al., 2007), l'algorithme ISBS peut être résumé en deux étapes : un pré-traitement linéaire d'image dans lequel la transformée discrète de Laplace est d'abord choisie afin de garantir une représentation parcimonieuse des images source.

Ensuite, une technique de gradient est sollicitée pour minimiser la norme l_p du mélange parcimonieux d'images.

Représentation parcimonieuse des images :

Le choix de la transformée de Laplace est motivé par le fait qu'elle est linéaire et agit comme un détecteur de contours qui assure une meilleure représentation parcimonieuse de l'image. Ceci permet donc d'offrir une image à deux niveaux les contours et le fond homogène (Background). Cette transformée est exprimée pour une image \mathbf{f} comme suit :

$$\mathbf{F} = \nabla \mathbf{f} = \frac{\partial^2 \mathbf{f}}{\partial x^2} + \frac{\partial^2 \mathbf{f}}{\partial y^2} \quad (5.8)$$

Dans le domaine discret, cette transformée de Laplace peut être donnée pour chaque pixel (m, n) de l'image par :

$$\mathbf{F}(m, n) = \mathbf{f}(m + 1, n) + \mathbf{f}(m - 1, n) + \mathbf{f}(m, n + 1) + \mathbf{f}(m, n - 1) - 4 \mathbf{f}(m, n) \quad (5.9)$$

La deuxième propriété fournie par la transformée de Laplace est sa linéarité qui garantit que la matrice estimée pour séparer le mélange des images naturelles, est la même que celle qui sépare le mélange des images transformées (parcimonieuses) par le Laplacien :

$$\mathbf{G} = \nabla \mathbf{g} = \frac{\partial^2 \mathbf{A}\mathbf{f}}{\partial x^2} + \frac{\partial^2 \mathbf{A}\mathbf{f}}{\partial y^2} = \mathbf{A}\mathbf{F} \quad (5.10)$$

où \mathbf{G} est la représentation parcimonieuse du mélange.

De la même manière que pour la méthode précédente de séparation basée sur les SOS, une étape de blanchiment est également requise dans ce cas de figure. Cette étape est appliquée au mélange parcimonieux résultant de la transformée de Laplace de telle manière que $cov(\mathbf{W}\mathbf{G}) = \mathbf{I}$ dans le cas sans bruit, où \mathbf{W} ($N \times M$) est la matrice de blanchiment, \mathbf{I} est la matrice identité et $cov(\cdot)$ désigne l'opérateur de covariance.

Finalement, nous obtenons les données suivantes (parcimonieuses et blanchies) pour

commencer le processus de séparation que nous allons détailler dans la section suivante :

$$\mathbf{G}_w(m, n) = \mathbf{W}\mathbf{G}(m, n) \quad (5.11)$$

Description de l'algorithme de séparation basé sur la parcimonie :

Après avoir rendu les mélanges parcimonieux en utilisant la transformée de Laplace, les auteurs de (Souidene et al., 2007) exploitent la propriété de parcimonie qui peut être mesurée à l'aide de la norme l_p sachant que ($0 \leq p < 2$). À cet effet, ils ont défini la fonction de contraste basée sur la parcimonie suivante :

$$\Psi_p(\mathbf{F}) = \sum_{i=1}^N [J_p(F_i)]^{\frac{1}{p}} \quad (5.12)$$

où

$$J_p(F_i) = \frac{1}{m_f n_f} \sum_{m=1}^{m_f} \sum_{n=1}^{n_f} |F_i(m, n)|^p \quad (5.13)$$

L'objectif principal de l'algorithme ISBS est d'estimer la matrice de séparation \mathbf{B} en minimisant la fonction de contraste donnée par :

$$\mathbf{B} = \arg \min_B \{\Psi_p(\mathbf{H})\} \quad (5.14)$$

où $\mathbf{H}(m, n) = \mathbf{B}\mathbf{G}_w(m, n)$ représente les images parcimonieuses estimées. Dans ce travail, la minimisation du critère donné par (5.14) est obtenue à l'aide d'une technique itérative proposée dans (Pham and Garat, 1997) dont l'estimation est achevée selon la formulation suivante :

$$\mathbf{B}^{(k+1)} = (\mathbf{I} + \boldsymbol{\epsilon}^{(k)}) \mathbf{B}^{(k)} \quad (5.15)$$

D'où :

$$\mathbf{H}^{(k+1)}(m, n) = (\mathbf{I} + \boldsymbol{\epsilon}^{(k)}) \mathbf{H}^{(k)}(m, n) \quad (5.16)$$

À la $k^{\text{ième}}$ itération et sous l'hypothèse que $\mathbf{B}^{(k)}$ soit très proche de la matrice de séparation. La méthode itérative ci-dessus devient une technique approximative de Newton avec l'avantage que la matrice $\boldsymbol{\epsilon}^{(k)}$ peut être calculée très simplement.

Dans ce cas de figure, la matrice $\boldsymbol{\epsilon}^{(k)}$ est déterminée à partir d'une linéarisation locale du

critère $\Psi_p(\mathbf{B}\mathbf{G}_w)$. Ainsi, par utilisation d'une technique de gradient, la matrice $\epsilon^{(k)}$ peut s'écrire comme :

$$\epsilon^{(k)} = -\mu \mathcal{D}^{(k)} \mathcal{R}^{(k)} \quad (5.17)$$

où $\mu > 0$ est le pas qui contrôle la descente du critère, et

$$\mathcal{D}^{(k)} = [\text{diag}([\mathcal{R}_{11}^{(k)}, \dots, \mathcal{R}_{NN}^{(k)}])]^{\frac{1}{p}-1} \quad (5.18)$$

Le (i, j) ^{ième} élément de la matrice $\mathcal{R}^{(k)}$, calculé à partir de l'approximation au premier ordre du critère $J_p(H_i^{(k+1)})$ sous l'hypothèse que $\mathbf{B}^{(k)}$ soit proche d'une matrice de séparation. À l'itération k , l'expression de $\mathcal{R}_{ij}^{(k)}$ est donnée par :

$$\mathcal{R}_{ij}^{(k)} = \frac{1}{m_f n_f} \sum_{m=1}^{m_f} \sum_{n=1}^{n_f} |H_i^{(k)}(m, n)|^{p-1} \text{sgn}(H_i^{(k)}(m, n)) H_j^{(k)}(m, n) \quad (5.19)$$

où $\text{sgn}(\cdot)$ se réfère à la fonction signe.

Finalement, la matrice de séparation estimée est donnée par $\mathbf{B} = \mathbf{B}^{(\mathcal{K})}\mathbf{W}$. Cette matrice est appliquée au mélange naturel des images \mathbf{g} pour obtenir une estimation des images originales $\hat{\mathbf{f}}$.

Avec \mathcal{K} le nombre d'itérations atteint, qui peut être choisi *a priori* ou donné par un critère d'arrêt de la forme $\|\mathbf{B}^{(k+1)} - \mathbf{B}^{(k)}\| < \delta$, où δ est un seuil choisi.

5.4 Approches proposées pour la séparation aveugle d'images

Dans cette section, nous présentons la méthodologie proposée, essentiellement basée sur deux contributions. La première concerne une méthode de séparation suivant un schéma 'dual', tandis que la seconde contribution est une méthode de séparation, accomplie à l'aide de la minimisation d'un critère 'hybride'. Ce critère exploite conjointement les statistiques de second ordre et la propriété parcimonieuse des sources images.

5.4.1 Approche duale pour la séparation aveugle d'images

Notre contribution consiste à introduire une structure algorithmique simple qui peut être utilisée comme approche efficace pour la séparation. La figure 5.1 illustre la configuration requise pour ce système.

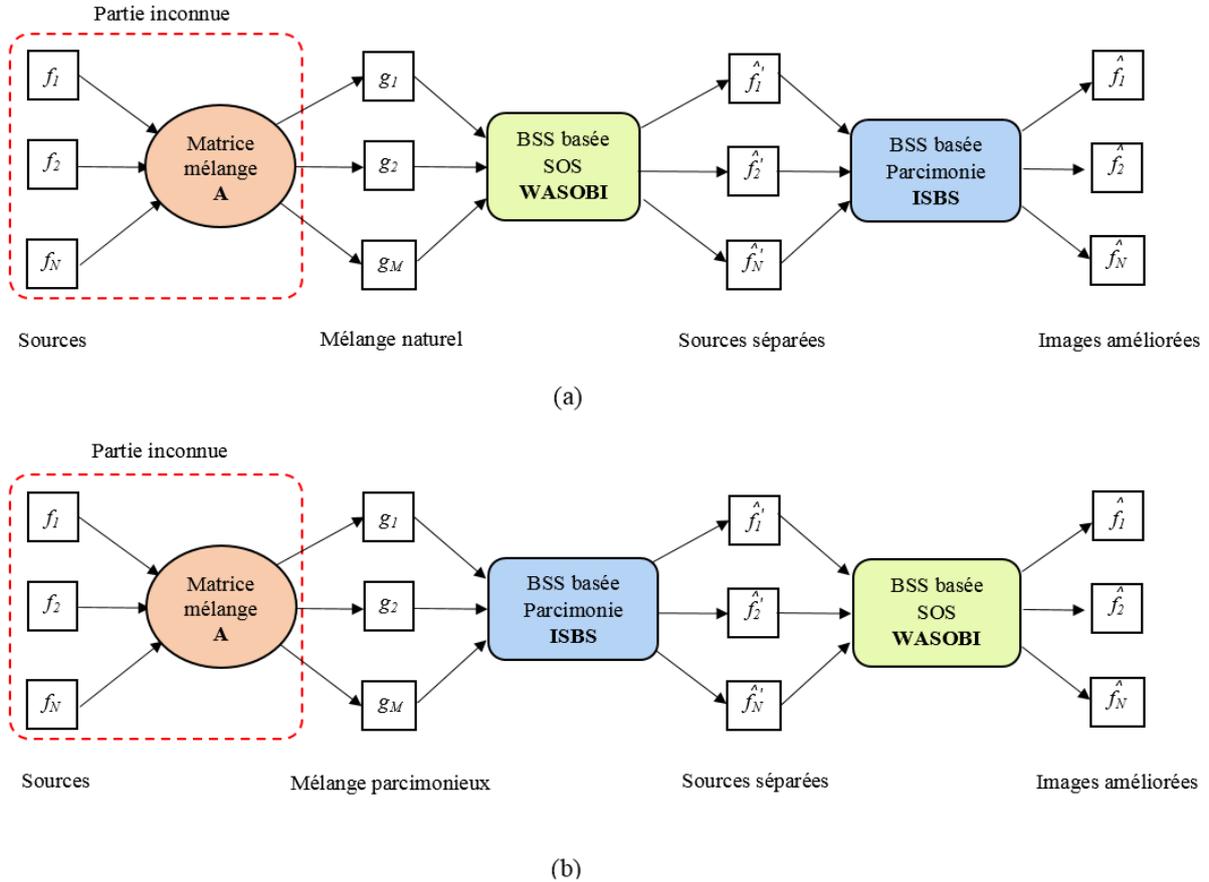


FIGURE 5.1 – Principe de l'approche duale pour la séparation aveugle d'images, (a) WASOBI suivie par ISBS et (b) ISBS suivie par WASOBI.

L'idée principale est d'exploiter les avantages tirés des statistiques de second ordre, en appliquant tout d'abord l'algorithme WASOBI, jusqu'au résultat optimal (final) de séparation d'images. Ensuite, la technique de séparation basée sur la représentation parcimonieuse des sources (algorithme ISBS) est appliquée pour affiner et améliorer la qualité de séparation (voir figure 5.1-(a)).

Nous procédons de la même manière dans le deuxième cas, le processus de séparation commence par exploiter la représentation parcimonieuse des mélanges à l'aide de l'algorithme ISBS, suivi par la technique WASOBI basée sur les statistiques du second ordre (voir figure 5.1-(b)).

5.4.2 Approche hybride pour la séparation aveugle d'images

Dans cette section, notre deuxième contribution consiste à tirer profit de toutes les informations (statistiques de second ordre et représentation parcimonieuse) disponibles dans les mélanges afin d'assurer une meilleure séparation des images. Par conséquent, pour étudier cette approche et évaluer ses performances, nous proposons d'intégrer les deux fonctions coût dans un critère hybride, \mathbf{C} , qui peut être défini comme suit :

$$\mathbf{C} = \lambda \mathbf{C}_{SOS} + (1 - \lambda) \mathbf{C}_{Sparse} \quad (5.20)$$

où le paramètre ($\lambda > 0$) qui équilibre les termes du critère hybride est choisi ici de manière *ad-hoc*³.

L'optimisation du critère résultant \mathbf{C} est réalisée en utilisant une simple technique de gradient qui exige une étape d'initialisation assurée par l'une des méthodes mentionnées précédemment (algorithme WASOBI ou ISBS).

Dans ce qui suit, nous allons détailler les expressions des deux termes constituant le critère hybride \mathbf{C} .

a) Critère basé sur les SOS :

L'expression du critère basé sur les statistiques de second ordre, \mathbf{C}_{SOS} est donnée par :

$$\mathbf{C}_{SOS}(\mathbf{B}) = \sum_{1 \leq i \neq j \leq N} \sum_{l=1}^L \zeta_l |R_{u_i u_j}(l)|^2 \quad (5.21)$$

où \mathbf{u} désigne l'estimation pondérée des sources donnée par l'équation (5.7) : $\mathbf{u} = \hat{\mathbf{f}} = \hat{\mathbf{U}}^* \hat{\mathbf{W}} \mathbf{g} = \mathbf{B} \mathbf{g}$.

ζ_l représente les pondérations et $R_{u_i u_j}$ est donnée par $R_{u_i u_j}(l) = E(u_i(t+l)u_j^*(t))$.

L est le nombre des matrices de corrélation.

3. Un des inconvénients de cette approche est la difficulté d'ajuster ce paramètre de manière optimale et simple.

Ceci implique que :

$$\begin{aligned}\mathbf{u}^{(k+1)} &= \mathbf{B}^{(k+1)} \mathbf{g} = (\mathbf{I} + \boldsymbol{\epsilon}^{(k)}) \mathbf{B}^{(k)} \mathbf{g} \\ &= (\mathbf{I} + \boldsymbol{\epsilon}^{(k)}) \mathbf{u}^{(k)}\end{aligned}\quad (5.22)$$

Par conséquent, le critère basé sur les SOS peut être reformulé à l'itération $k + 1$ comme suit :

$$\mathbf{C}_{SOS}(\mathbf{B}^{(k+1)}) = \mathbf{C}_{SOS}(\mathbf{B}^{(k)}) + Tr(\boldsymbol{\epsilon}^{(k)} \boldsymbol{\mathcal{M}}^{(k)}) \quad (5.23)$$

où $Tr(\cdot)$ est la trace d'une matrice et $\boldsymbol{\mathcal{M}}$ est donnée par :

$$\begin{aligned}\boldsymbol{\mathcal{M}}^{(k)} &= 2 \sum_{l=1}^L \rho_l [R_u^{(k)T} R_u^{(k)}(l) + R_u^{(k)} R_u^{(k)T}(l) - R_u^{(k)}(l) \text{diag}(R_u^{(k)}(l)) \\ &\quad - \text{diag}(R_u^{(k)}(l)) R_u^{(k)T}(l)]\end{aligned}\quad (5.24)$$

b) **Critère basé sur la parcimonie :**

En utilisant l'approximation au premier ordre de $J_p(H_i^{(k+1)})$ à l'itération $k + 1$, la fonction de contraste basée sur la parcimonie donnée par l'équation (5.12) peut être écrite sous une forme compacte comme suit :

$$\mathbf{C}_{Sparse}(\mathbf{B}^{(k+1)}) = \mathbf{C}_{Sparse}(\mathbf{B}^{(k)}) + Tr(\boldsymbol{\epsilon}^{(k)} \boldsymbol{\mathcal{R}}^{(k)T} \boldsymbol{\mathcal{D}}^{(k)}) \quad (5.25)$$

Les matrices $\boldsymbol{\mathcal{D}}$ et $\boldsymbol{\mathcal{R}}$ sont exprimées dans les équations (5.18) et (5.19), respectivement.

Par la suite, le remplacement des deux termes donnés par les équations (5.23), (5.25) dans l'équation (5.20) conduit à exprimer le critère hybride \mathbf{C} comme suit :

$$\begin{aligned}\mathbf{C}(\mathbf{B}^{(k+1)}) &= \lambda \mathbf{C}_{SOS}(\mathbf{B}^{(k+1)}) + (1 - \lambda) \mathbf{C}_{Sparse}(\mathbf{B}^{(k+1)}) \\ &= \lambda \mathbf{C}_{SOS}(\mathbf{B}^{(k)}) + (1 - \lambda) \mathbf{C}_{Sparse}(\mathbf{B}^{(k)}) \\ &\quad + Tr(\boldsymbol{\epsilon}^{(k)} (\lambda \boldsymbol{\mathcal{R}}^{(k)T} \boldsymbol{\mathcal{D}}^{(k)} + (1 - \lambda) \boldsymbol{\mathcal{M}}^{(k)})) \\ &= \mathbf{C}(\mathbf{B}^{(k)}) + Tr(\boldsymbol{\epsilon}^{(k)} (\lambda \boldsymbol{\mathcal{R}}^{(k)T} \boldsymbol{\mathcal{D}}^{(k)} \\ &\quad + (1 - \lambda) \boldsymbol{\mathcal{M}}^{(k)}))\end{aligned}\quad (5.26)$$

L'optimisation du critère résultant est effectuée par utilisation de la technique du gradient qui permet d'écrire la matrice $\epsilon^{(k)}$ sous la forme suivante :

$$\epsilon^{(k)} = -\mu ((1 - \lambda)\mathcal{M}^{(k)T} + \lambda \mathcal{D}^{(k)}\mathcal{R}^{(k)}) \quad (5.27)$$

Dans la section suivante, nous allons évaluer les performances des deux approches de séparation proposées (dual et hybride).

5.5 Résultats et discussion

Cette section présente les performances du schéma proposé pour la séparation aveugle d'images. Afin de tester la robustesse de nos algorithmes, les résultats expérimentaux sont obtenus en appliquant nos techniques de séparation à différents types d'images, soit à des images photographiques (Cameraman (256×256), Parrot (512×512)) ou à des images médicales obtenues par la technique DEXA (Dual Energy X-ray Absorption). À chaque fois, deux images sont considérées pour simuler des mélanges linéaires 2×2 à l'aide d'une matrice de mélange aléatoire \mathbf{A} de taille (2×2).

Pour comparer les performances de nos algorithmes proposés (développés sous environnement Matlab), plusieurs critères ont été utilisés : le rapport signal/bruit de crête *PSNR* en *dB* et l'indice *SSIM*, définis comme suit :

$$PSNR = 10 \times \log \frac{255^2}{MSE} \quad [dB] \quad (5.28)$$

$$SSIM = \frac{2\mu_f\mu_{\hat{f}} + C_1}{\mu_f^2 + \mu_{\hat{f}}^2 + C_1} \times \frac{2\sigma_{f\hat{f}} + C_2}{\sigma_f^2 + \sigma_{\hat{f}}^2 + C_2} \quad (5.29)$$

où *MSE* est l'erreur quadratique moyenne par pixel. (μ_f, σ_f^2) et $(\mu_{\hat{f}}, \sigma_{\hat{f}}^2)$ sont la moyenne et la variance des images originales \mathbf{f} et de leurs estimées $\hat{\mathbf{f}}$, respectivement. $\sigma_{f\hat{f}}$ est la covariance de \mathbf{f} et $\hat{\mathbf{f}}$. c_1 et c_2 sont des constantes exprimées comme suit : $c_1 = (K_1 \times L)^2$ et $c_2 = (K_2 \times L)^2$ avec $L = 255$, la dynamique des images ($L = 255$). Les constantes K_1 et K_2 sont égales à 0.01 et 0.03, respectivement.

5.5.1 Évaluation de la performance de l’approche duale de séparation

Cette section présente les résultats de la séparation d’images en utilisant le schéma dual proposé dans la figure 5.1. Le processus de séparation est effectué sur des mélanges naturels (images non parcimonieuses) pour le cas de l’approche basée sur les SOS (algorithme WASOBI) et sur des mélanges parcimonieux (produits par la transformée de Laplace) pour l’approche basée sur la parcimonie (algorithme ISBS).

La figure 5.2 illustre les différents mélanges utilisés pendant les expériences (images sources, mélange naturel et parcimonieux d’images).

En utilisant le mélange naturel et parcimonieux des images de la figure 5.2, nous procédons à la séparation en respectant le cadre algorithmique donné par la figure 5.1. Tout d’abord, l’algorithme ISBS a été appliqué sur le mélange parcimonieux d’images donné par les figures 5.2 (e)-(f). Lorsque ce dernier a atteint son résultat optimal, l’algorithme WASOBI basé sur les SOS est ensuite appliqué pour améliorer davantage la séparation comme le montre la figure 5.3.

De la même façon, la figure 5.4 montre les résultats obtenus lors de l’exploitation des SOS dans le cas du mélange naturel d’images (figure 5.2 (c)-(d)) en premier, suivie par une étape de raffinement de la qualité de séparation en utilisant la technique basée sur la parcimonie (algorithme ISBS). Dans ce cas de figure, un prétraitement (transformation de Laplace) est exigé sur les images produites par l’algorithme WASOBI.

Le tableau 5.1 résume l’amélioration significative de la qualité de séparation selon le schéma proposé. Le gain d’amélioration mentionné a été calculé comme étant le rapport entre les résultats obtenus par l’algorithme ISBS (ou WASOBI) et son successeur WASOBI (ou ISBS).

Il convient de noter que les meilleurs résultats sont obtenus en appliquant tout d’abord la méthode de décorrélation (algorithme WASOBI) puis la méthode basée sur la parcimonie (algorithme ISBS). Cette observation préliminaire devrait être confirmée par des résultats de simulation plus intensifs.

Globalement, ces résultats indiquent toujours une amélioration dans la qualité de la

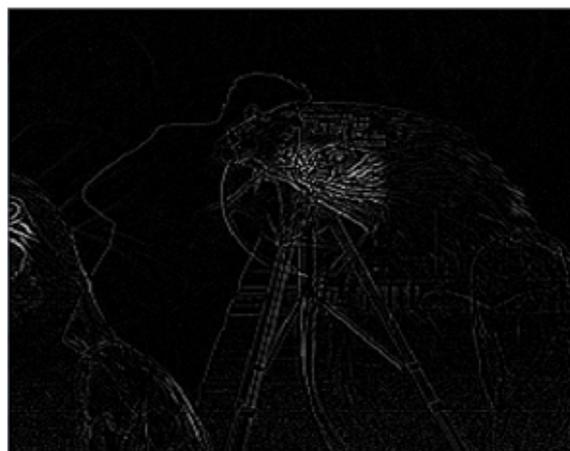
(a) Image source f_1 (b) Image source f_2 (c) Mélange naturel g_1 (d) Mélange naturel g_2 (e) Mélange parcimonieux G_1 (f) Mélange parcimonieux G_2

FIGURE 5.2 – Deux images sources (a)-(b) avec leurs mélanges naturels (c)-(d) et leurs mélanges parcimonieux (e)-(f) obtenus à l'aide de la transformée de Laplace.

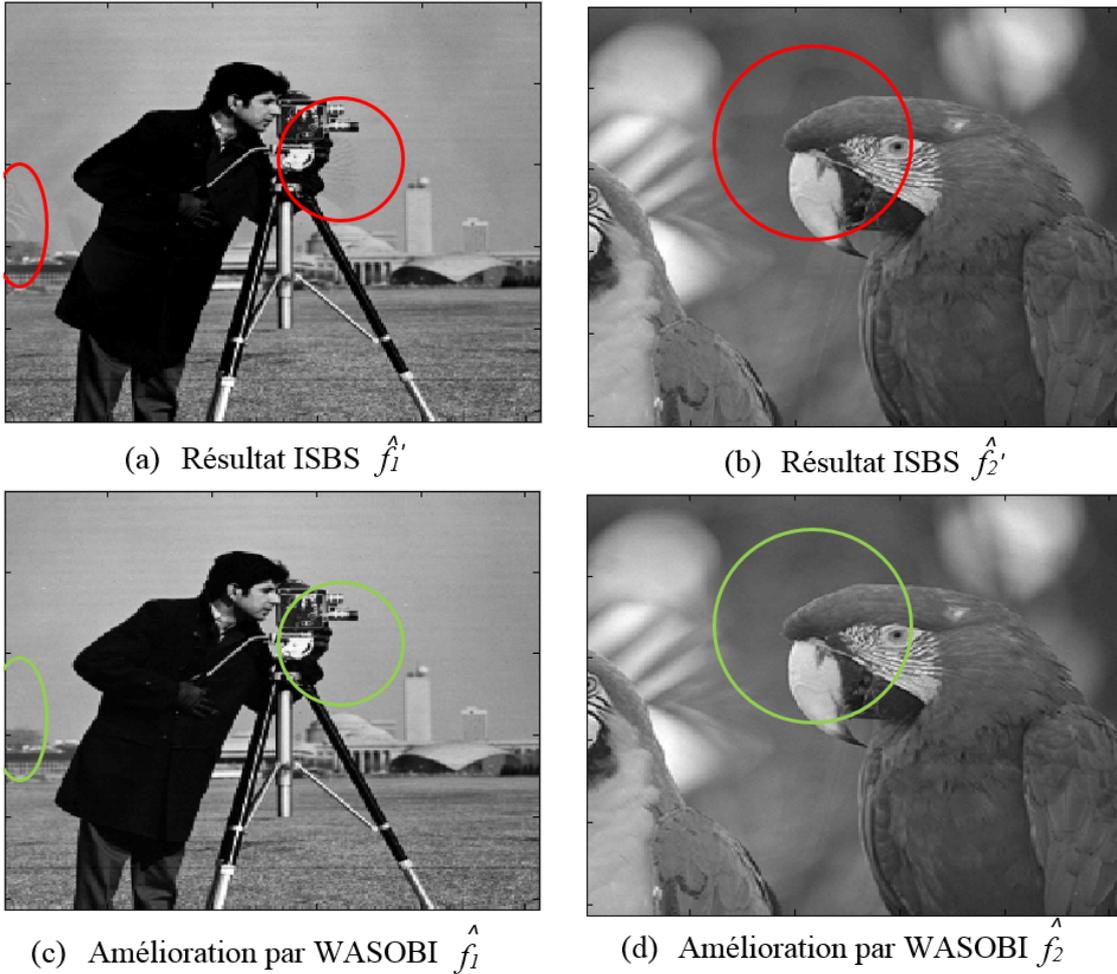


FIGURE 5.3 – Performances de l’approche duale de séparation (résultat de l’algorithme ISBS (a)-(b) suivi de l’amélioration par l’algorithme WASOBI (c)-(d)). Le cercle rouge indique les défauts et imperfections de la séparation. Le cercle vert montre l’amélioration obtenue.

TABLE 5.1 – Évaluation des performances de l’approche duale proposée pour les deux sources images, Cameraman (S1) et Parrot (S2).

	ISBS	ISBS-WASOBI	WASOBI	WASOBI-ISBS
SSIM (S1)	0.9794	0.9948	0.9956	0.9999
PSNR (S1)	38.18	43.09	41.21	56.36
SSIM (S2)	0.9358	0.9717	0.8665	0.9994
PSNR (S2)	32.61	38.35	24.41	54.21

séparation aveugle d’images et consolident donc notre idée d’exploiter toutes les informations disponibles dans les mélanges, soit séparément (schéma dual) ou conjointement, comme cela apparaîtra dans la section suivante.

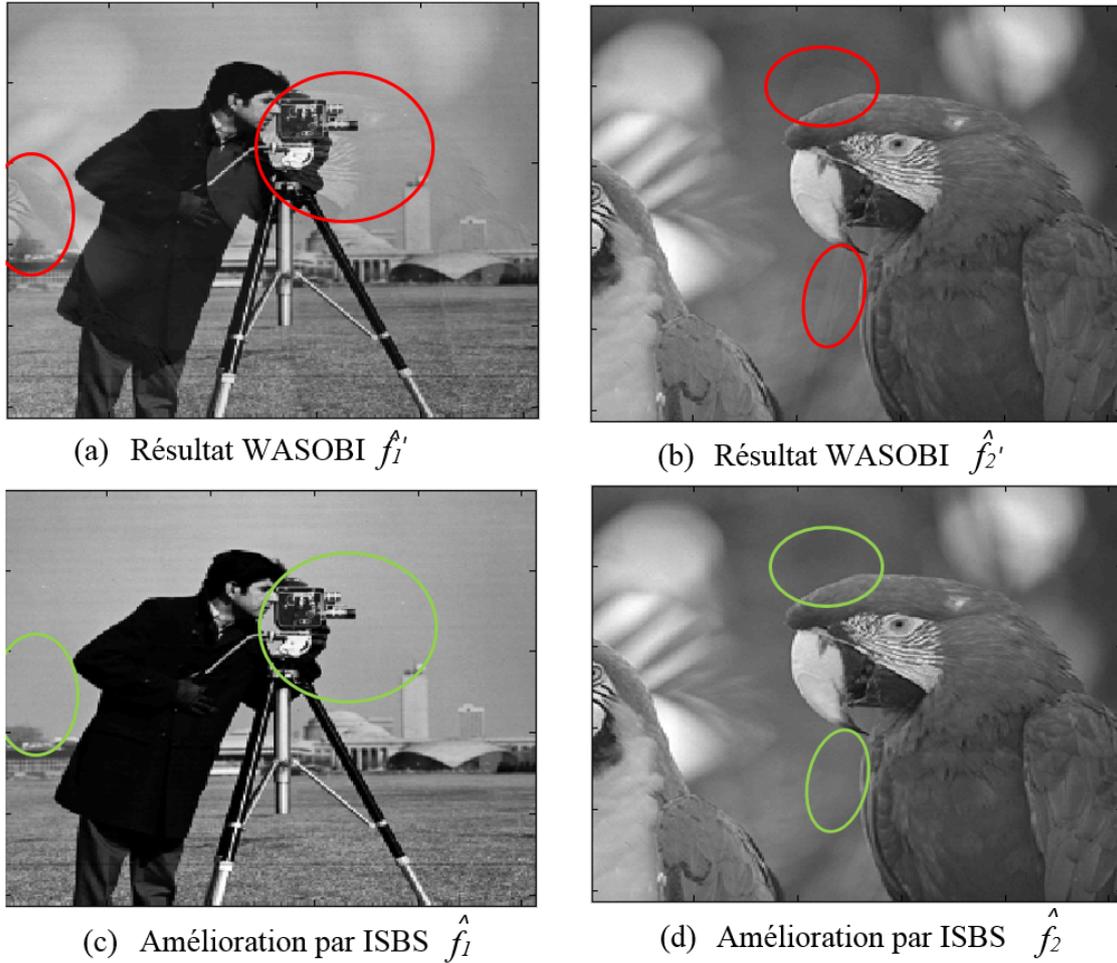


FIGURE 5.4 – Performance de l’approche duale de séparation (résultat de l’algorithme WASOBI (a)-(b)). Amélioration obtenue par application successive de l’algorithme ISBS (c)-(d).

5.5.2 Séparation aveugle d’images basée sur la minimisation d’un critère hybride

À partir de la formulation détaillée du critère hybride exprimé par l’équation (5.26) et à l’aide d’une technique d’optimisation itérative basée sur la descente du gradient (GD) donnée par l’équation (5.27), nous étudions dans cette section les avantages et l’intérêt de l’exploitation conjointe des SOS et de la représentation parcimonieuse des mélanges. Pour les expérimentations, le pas μ a été fixé à sa valeur optimale 0.05.

La figure 5.5 présente les résultats de séparation obtenus, en utilisant le critère basé sur les SOS, \mathcal{C}_{SOS} exprimé pour $\lambda = 1$ (figure 5.5 (a)-(b)). Les résultats obtenus à l’aide du critère basé sur la parcimonie, \mathcal{C}_{Sparse} avec $\lambda = 0$ sont illustrés dans la figure 5.5 (c)-(d). La séparation réalisée à l’aide de notre algorithme hybride \mathcal{C} est présentée dans sur les

5.5. RÉSULTATS ET DISCUSSION

figures 5.5 (e)-(f) pour $\lambda = 0.6$.



(a) $SSIM=0.9388$, $PSNR=31.64$



(b) $SSIM=0.9928$, $PSNR=39.02$



(c) $SSIM=0.9824$, $PSNR=38.97$



(d) $SSIM=0.9985$, $PSNR=46.58$



(e) $SSIM=0.9996$, $PSNR=55.27$



(f) $SSIM=0.9999$, $PSNR=56.02$

FIGURE 5.5 – Résultats de séparation aveugle d'images en utilisant l'approche hybride proposée (e)-(f), comparés aux images restaurées par l'algorithme WASOBI (a)-(b) et aux images restaurées par l'algorithme ISBS (c)-(d).

Cette étude comparative (performance de la qualité de séparation en termes de *SSIM* et *PSNR*) valide l'efficacité de notre algorithme et les résultats obtenus montrent l'avantage d'exploiter conjointement plusieurs informations sur les mélanges. Les résultats obtenus sont comparables à ceux obtenus en utilisant la méthode duale WASOBI-ISBS. Cependant, les performances de l'approche hybride dépendent fortement du paramètre de pondération λ , dont l'optimisation reste un problème ouvert et difficile.

5.5.3 Séparation aveugle d'images médicales

Dans cette section, les performances de notre approche sont évaluées sur des images médicales spécifiques. Ces images médicales correspondent à des scans de différentes natures réalisés à l'aide de plusieurs types de modalités d'acquisition DEXA, HR-pQCT et IRM (Adams, 2013). Les scans ont été réalisées sur différentes régions du corps humain (tibia, cerveau, genou et tête du fémur) selon des sections ou coupes transversale, axiale, coronale et sagittale.

Les mélanges sont calculés manuellement⁴ en utilisant la matrice de mélange \mathbf{A} . La figure 5.6 montre les résultats de séparation pour le mélange d'un genou (a) et une tête de fémur (b). La figure 5.7 montre les résultats de séparation dans le cas de mélange d'un cerveau (a) et d'un tibia (b) avec une coupe axiale.

Comme nous pouvons le constater, le test sur ce type d'images renforce largement l'efficacité de notre approche et confirme l'idée de la complémentarité entre les différentes informations disponibles dans ces mélanges. En utilisant l'approche hybride, la qualité de séparation a été intensifiée avec un gain élevé d'amélioration.

5.6 Conclusion

Dans ce chapitre, nous avons introduit une nouvelle approche pour la séparation aveugle d'images basée sur l'exploitation conjointe des avantages dérivés à la fois des caractéris-

4. Ce sont des mélanges 'artificiels' considérés uniquement pour l'évaluation des performances et à des fins de comparaison.

5.6. CONCLUSION

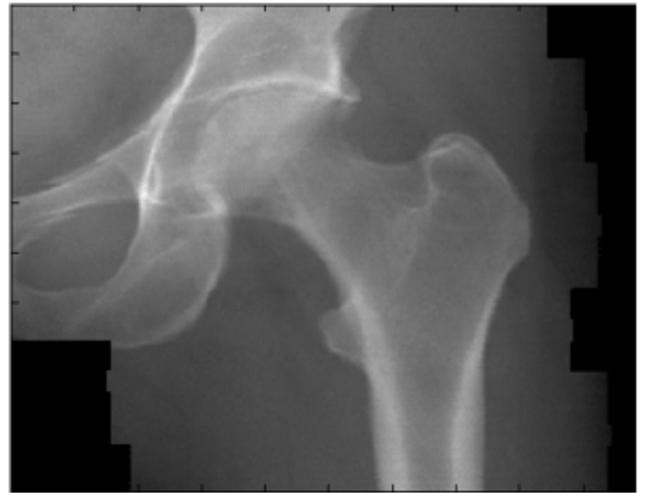
tiques statistiques et de la représentation parcimonieuse des signaux sources.

Deux approches sont proposées. L'approche dite 'duale', qui consiste à raffiner la qualité de la séparation d'une manière séquentielle et l'approche 'hybride', qui repose sur la minimisation d'un critère combiné en utilisant un algorithme itératif.

Les performances de nos algorithmes ont été évaluées sur différents types d'images (images photographiques et médicales). Les simulations illustrent l'efficacité des méthodes proposées et leur potentiel prometteur pour améliorer davantage les techniques existantes de séparation aveugle d'images .



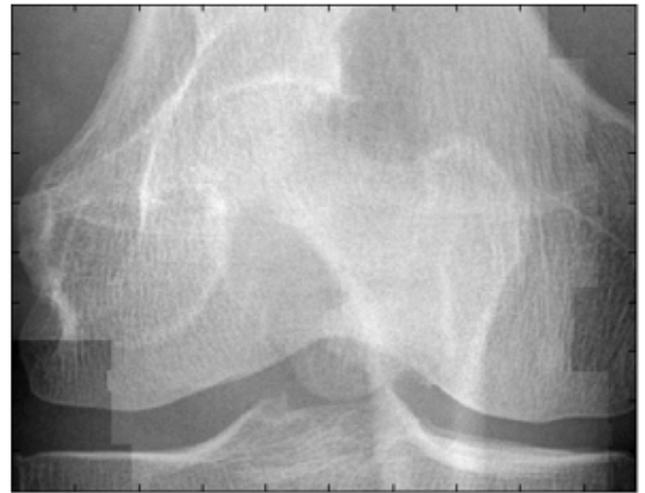
(a) Image source Genou



(b) Image source Tête de fémur



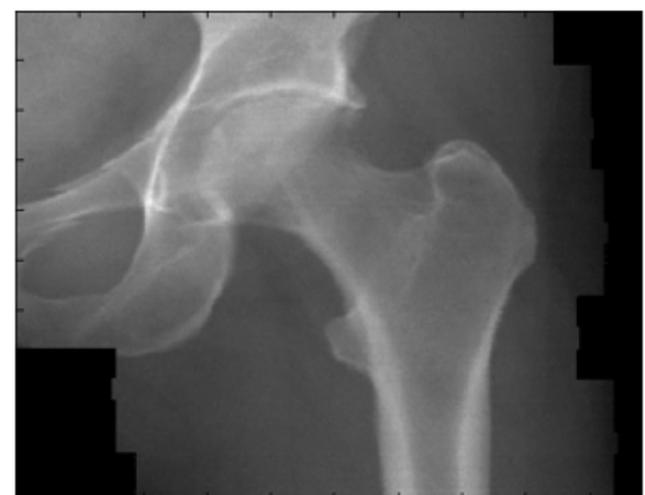
(c) $SSIM=0.4792$, $PSNR=17.06$



(d) $SSIM=0.8319$, $PSNR=20.09$

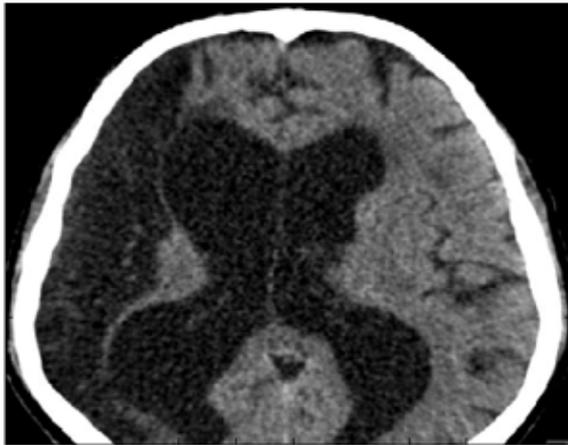


(e) $SSIM=0.9604$, $PSNR=36.92$

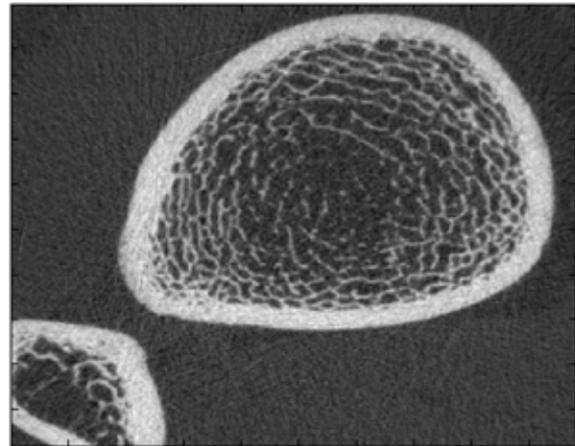


(f) $SSIM=0.9976$, $PSNR=41.31$

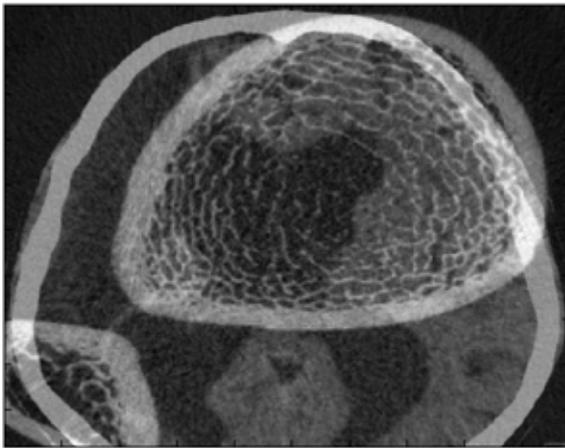
FIGURE 5.6 – Mélange d'images médicales (c)-(d), résultats de la séparation avec l'approche hybride proposée (e)-(f).



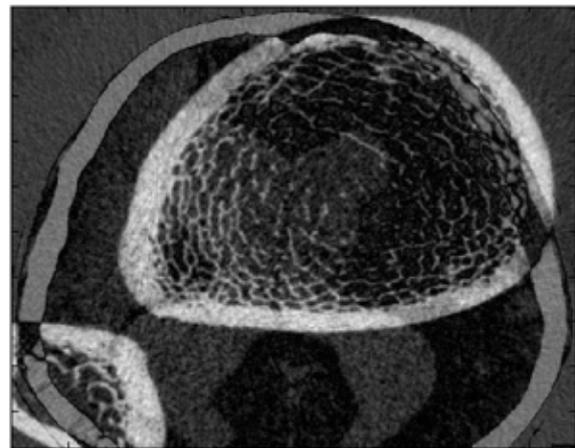
(a) Image source Cerveau



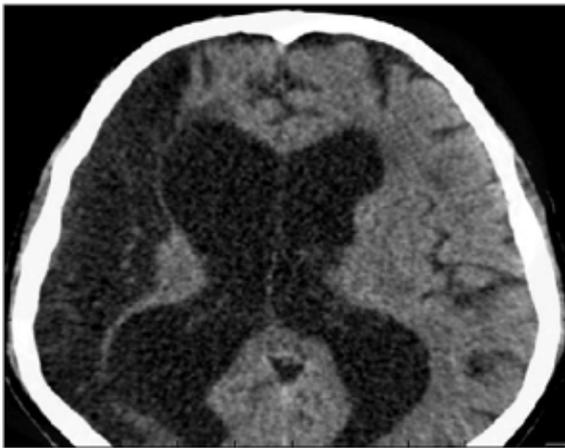
(b) Image source Tibia



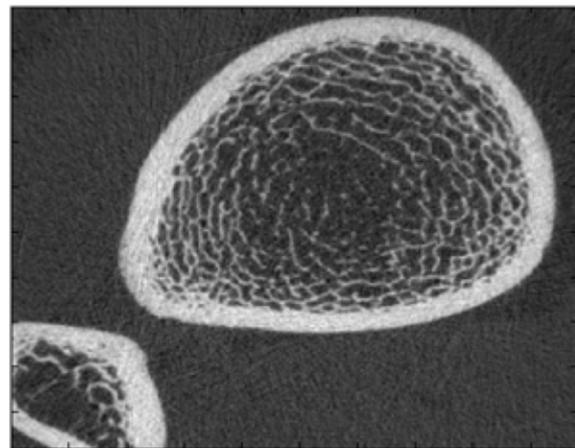
(c) $SSIM=0.4231$, $PSNR=13.91$



(d) $SSIM=0.5502$, $PSNR=15.15$



(e) $SSIM=0.9907$, $PSNR=52.50$



(f) $SSIM=0.9319$, $PSNR=36.48$

FIGURE 5.7 – Mélange d'images médicales avec des scans axiales (c)-(d), résultats de la séparation avec l'approche hybride proposée (e)-(f).

Conclusion générale et perspectives

Conclusion

À travers ce travail, nous avons abordé plusieurs aspects liés au problème de la restauration aveugle d'images dans le cas multi-canal. Pour atteindre les objectifs réalisés dans ce travail, nous avons tout d'abord, mené une étude comparative des différentes approches proposées dans la littérature. Ensuite, nous nous sommes attaché à construire une chaîne complète pour la restauration aveugle 2D.

Concernant les objectifs définis dans cette étude, tout d'abord, nous avons proposé une technique d'identification aveugle pour un système à entrée unique et sorties multiples où l'ordre du canal est inconnu (surestimé). Deux méthodes ont été décrites. Une version simplifiée, dites des relations croisées symétrique (dite **SCR**) avec un bon compromis entre complexité numérique et performance d'estimation. Ainsi qu'une version robuste (dite **R-SCR**) basée sur la recherche d'une solution parcimonieuse minimisant la fonction de coût CR. Les simulations réalisées démontrent les potentiels des algorithmes proposés. Toutefois, il reste à améliorer la méthode R-SCR afin de mieux concilier sa robustesse aux erreurs de l'ordre du canal et celle aux effets du bruit additif.

Ensuite, nous avons proposé une nouvelle approche pour la restauration d'images dans un contexte multi-canal, en exploitant l'algorithme de décodage séquentiel '**Stack**' inspiré des techniques 1D. Plusieurs versions ont été proposées. Une basée sur l'exploitation de la structure à bande limitée de la matrice de filtrage (**Stack-BL**) et élaborée sous forme d'une recherche hiérarchique (**Stack-Hiérarchique**). Par la suite, nous avons eu recours à une régularisation afin de rendre l'approche proposée robuste aux effets du bruit additif (**Stack-TV**(l_1, l_2)). Ainsi, un algorithme de minimisation '*All-at-once*' basé sur la mé-

thode de la descente du gradient et proposé pour raffiner le résultat initialement obtenu (**Stack-DG**).

Puis, nous avons proposé une idée originale en introduisant l'indice de similarité structurelle (SSIM : Structural SIMilarity index) utilisé pour évaluer et comparer les résultats de restauration d'image dans le critère de restauration. La métrique SSIM est introduite dans la fonction coût. Le critère résultant est alors minimisé à l'aide de la descente du gradient. Les résultats préliminaires obtenus sont encourageants et montrent le potentiel de la méthode proposée.

Enfin, nous avons évalué et exploité les performances de deux techniques de séparation de sources aveugle (WASOBI et ISBS) afin d'améliorer la qualité de séparation des images. Les techniques proposées exploitent conjointement les avantages dérivés à la fois des caractéristiques statistiques et de la représentation parcimonieuse des signaux sources. Les simulations réalisées prouvent l'efficacité des méthodes proposées et leur potentiel prometteur pour améliorer davantage les techniques existantes de la séparation aveugle d'images.

En résumé, les performances des techniques proposées dans ce travail ont été évaluées en analysant la qualité de restauration à l'aide de plusieurs simulations numériques. Nos approches ont été testées pour la restauration d'images dans plusieurs cas de figures : complexité numérique, robustesse aux effets du bruit et aux erreurs d'estimation de l'ordre du canal. Les résultats obtenus sont prometteurs et ouvrent la voie à de nombreux travaux futurs.

Perspectives

Comme perspectives nous pouvons citer quelques améliorations des techniques proposées et aussi mentionner les points non abordés durant ce travail. Ainsi, il faudrait

- améliorer la méthode R-SCR afin de mieux concilier sa robustesse aux erreurs de l'ordre du canal, aux effets du bruit additif et au nombre de canaux ;
- examiner d'autres termes de régularisation (par exemple la décomposition en onde-

- lettres) en respectant la structure exigée par l'algorithme Stack ;
- automatiser les différents paramètres de régularisation, paramètres de pénalité, pas de la descente du gradient, etc. ;
 - utiliser d'autres métriques que l'indice SSIM ;
 - trouver un outil afin d'exploiter la quantité d'information a priori nécessaire comme référence pour comparaison (métrique à référence partielle) ;
 - exploiter les techniques développées pour la séparation aveugle d'images pour envisager une meilleure segmentation dans une application médicale.

Bibliographie

- Abed-Meraim, K., Loubaton, P., and Moulines, E. (1997a). A subspace algorithm for certain blind identification problems. *IEEE transactions on information theory*, 43(2) :499–511. (Cité en page 42).
- Abed-Meraim, K., Moulines, E., and Loubaton, P. (1997b). Prediction error method for second-order blind identification. *IEEE Transactions on Signal Processing*, 45(3) :694–705. (Cité en page 10).
- Abed-Meraim, K., Qiu, W., and Hua, Y. (1997c). Blind system identification. *Proceedings of the IEEE*, 85(8) :1310–1322. (Cité en pages 34 et 42).
- Abed-Meraim, K., Xiang, Y., Manton, J. H., and Hua, Y. (2001). Blind source-separation using second-order cyclostationary statistics. *IEEE Transactions on Signal Processing*, 49(4) :694–701. (Cité en page 28).
- Abediseid, W. and Alouini, M.-S. (2013). On lattice sequential decoding for the unconstrained awgn channel. *IEEE Transactions on Communications*, 61(6) :2446–2456. (Cité en page 53).
- Acar, E., Dunlavy, D. M., and Kolda, T. G. (2011). A scalable optimization approach for fitting canonical tensor decompositions. *Journal of Chemometrics*, 25(2) :67–86. (Cité en page 89).
- Adams, J. E. (2013). Advances in bone imaging for osteoporosis. *Nature Reviews Endocrinology*, 9(1) :28–42. (Cité en page 114).
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6) :716–723. (Cité en page 10).
- Andrei, N. (2004). Relaxed gradient descent and a new gradient descent methods for unconstrained optimization. *Submitted for Publication to Journal of Mathematical Programming,* " <http://www.ici.ro/camo/neculai/newgrad.pdf> @ 02/22/2005"; also : *ICI Technical Report*. (Cité en pages 64, 79 et 87).
- Araujo, E., Araujo, F. P., Becceneri, J. C., and Velho, H. F. C. (2009). Particle swarm optimization with turbulence (psot) applied to thermal-vacuum modelling. In *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on*, pages 344–349. IEEE. (Cité en page 19).
- Ayers, G. and Dainty, J. C. (1988). Iterative blind deconvolution method and its applications. *Optics letters*, 13(7) :547–549. (Cité en page 17).

- Banham, M. R. and Katsaggelos, A. K. (1997). Digital image restoration. *IEEE signal processing magazine*, 14(2) :24–41. (Cité en page 7).
- Barhate, M. (2013). Separation of mixed images using independent component analysis on the basis of blind source separation. *International Journal of Advanced Electronics and Communication Systems*, 1(3). (Cité en page 30).
- BekkatAT (1999). *Critère objectifs de qualité subjective d’images monochromes*. Thèse de doctorat, IRESTE. (Cité en page 21).
- Bell, A. J. and Sejnowski, T. J. (1995). An information-maximization approach to blind separation and blind deconvolution. *Neural computation*, 7(6) :1129–1159. (Cité en page 31).
- Belouchrani, A., Abed-Meraim, K., Cardoso, J.-F., and Moulines, E. (1997). A blind source separation technique using second-order statistics. *IEEE Transactions on signal processing*, 45(2) :434–444. (Cité en pages 29, 99 et 101).
- Bi, X.-j. and Wang, T. (2008). Adaptive blind image restoration algorithm of degraded image. In *Image and Signal Processing, 2008. CISP’08. Congress on*, volume 3, pages 536–540. IEEE. (Cité en page 19).
- Biemond, J., Lagendijk, R. L., and Mersereau, R. M. (1990). Iterative methods for image deblurring. *Proceedings of the IEEE*, 78(5) :856–883. (Cité en page 52).
- Bingham, E. and Hyvärinen, A. (2000). A fast fixed-point algorithm for independent component analysis of complex valued signals. *International journal of neural systems*, 10(01) :1–8. (Cité en page 31).
- Bishop, T. E. and Hopgood, J. R. (2006). Blind image restoration using a block-stationary signal model. In *Acoustics, Speech and Signal Processing, 2006. ICASSP 2006 Proceedings. 2006 IEEE International Conference on*, volume 2, pages II–II. IEEE. (Cité en page 14).
- Bofill, P. and Zibulevsky, M. (2001). Underdetermined blind source separation using sparse representations. *Signal processing*, 81(11) :2353–2362. (Cité en page 98).
- Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2016a). On the use of all-at-once optimization technique for image restoration quality improvement. In *Proceedings of The First International Conference of High Innovation in Computer Science*, pages 159–162. (Cité en page 86).
- Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2016b). On the use of image quality measures for image restoration. In *Image Processing Theory Tools and Applications (IPTA), 2016 6th International Conference on*, pages 1–6. IEEE. (Cité en page 63).
- Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2017). Identification aveugle 2d robuste à la surestimation de l’ordre. In *Image and Signal Processing and their Applications (ISPA 2017)*. ISPA. (Voir publications).
- Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2018a). Blind image

BIBLIOGRAPHIE

- separation using composite criteria based on statistical information and sparse representation. *à soumettre prochainement*. (Voir publications).
- Boudjenouia, F., Abed-Meraim, K., Chetouani, A., and Jennane, R. (2018b). Blind multichannel image restoration using stack decoder. *à soumettre dans IET Image Processing*. (Voir publications).
- Boudjenouia, F., Jennane, R., Abed-Meraim, K., and Chetouani, A. (2016c). Sequential stack decoder for multichannel image restoration. In *Signal Processing Conference (EUSIPCO), 2016 24th European*, pages 1293–1297. IEEE. (Cité en pages 47, 58 et 61).
- Bovik, A. C. (2009). *The essential guide to image processing*. Academic Press. (Cité en page 52).
- Bradley, A. P. (1999). A wavelet visible difference predictor. *IEEE transactions on image processing*, 8(5) :717–730. (Cité en page 24).
- Bronstein, M. M., Bronstein, A. M., Zibulevsky, M., and Zeevi, Y. Y. (2003). Separation of reflections via sparse ica. In *Image Processing, 2003. ICIP 2003. Proceedings. 2003 International Conference on*, volume 1, pages I–313. IEEE. (Cité en page 98).
- Cai, J.-F., Ji, H., Liu, C., and Shen, Z. (2009). Blind motion deblurring from a single image using sparse approximation. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 104–111. IEEE. (Cité en page 35).
- Cannon, M. (1976). Blind deconvolution of spatially invariant image blurs with phase. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 24(1) :58–63. (Cité en page 14).
- Cardoso, J.-F. (1989). Source separation using higher order moments. In *Acoustics, Speech, and Signal Processing, 1989. ICASSP-89., 1989 International Conference on*, pages 2109–2112. IEEE. (Cité en page 97).
- Cardoso, J.-F. and Souloumiac, A. (1996). Jacobi angles for simultaneous diagonalization. *SIAM journal on matrix analysis and applications*, 17(1) :161–164. (Cité en page 32).
- Chabrier, S., Emile, B., Rosenberger, C., and Laurent, H. (2006). Unsupervised performance evaluation of image segmentation. *EURASIP Journal on Applied Signal Processing*, 2006 :217–217. (Cité en page 88).
- Chandler, D. M. (2013). Seven challenges in image quality assessment : past, present, and future research. *ISRN Signal Processing*, 2013. (Cité en page 83).
- Channappayya, S. S., Bovik, A. C., Caramanis, C., and Heath, R. W. (2008a). Ssim-optimal linear image restoration. In *Acoustics, Speech and Signal Processing, 2008. ICASSP 2008. IEEE International Conference on*, pages 765–768. IEEE. (Cité en page 23).
- Channappayya, S. S., Bovik, A. C., Heath Jr, R. W., and Caramanis, C. (2008b). Rate bounds on ssim index of quantized image dct coefficients. In *Data Compression Conference, 2008. DCC 2008*, pages 352–361. IEEE. (Cité en page 85).

- Chen, G.-H., Yang, C.-L., and Xie, S.-L. (2006). Gradient-based structural similarity for image quality assessment. In *Image Processing, 2006 IEEE International Conference on*, pages 2929–2932. IEEE. (Cité en page 25).
- Chichocki, A. (2015). Adaptive blind signal and image processing. (Cité en page 30).
- Chickerur, S. and Kumar, A. (2008). A robust cluster based approach for image restoration. In *Image and Signal Processing, 2008. CISP'08. Congress on*, volume 1, pages 370–374. IEEE. (Cité en page 19).
- Cichocki, A. and Amari, S.-i. (2002). *Adaptive blind signal and image processing : learning algorithms and applications*, volume 1. John Wiley & Sons. (Cité en pages 27 et 29).
- Comon, P. (1994). Independent component analysis, a new concept? *Signal processing*, 36(3) :287–314. (Cité en pages 30 et 97).
- Comon, P. and Jutten, C. (2010). *Handbook of Blind Source Separation : Independent component analysis and applications*. Academic press. (Cité en page 97).
- Daly, S. (1993). The visible differences predictor : an algorithm for the assessment of image fidelity. *Digital images and human vision*, 4 :124–125. (Cité en page 24).
- Damen, M. O., El Gamal, H., and Caire, G. (2003). On maximum-likelihood detection and the search for the closest lattice point. *IEEE Transactions on information theory*, 49(10) :2389–2402. (Cité en page 53).
- De Lathauwer, L., De Moor, B., and Vandewalle, J. (1996). Independent component analysis based on higher-order statistics only. In *Statistical Signal and Array Processing, 1996. Proceedings., 8th IEEE Signal Processing Workshop on (Cat. No. 96TB10004*, pages 356–359. IEEE. (Cité en page 28).
- Duy, L. (2009). Review and enhancement optimization methods in image registration. *MEng. Computing, Department of Computing, Imperial College London*. (Cité en pages 63 et 86).
- Eskicioglu, A. M. and Fisher, P. S. (1995). Image quality measures and their performance. *IEEE Transactions on communications*, 43(12) :2959–2965. (Cité en page 79).
- Fan, Q., Jiang, D., and Jiao, Y. (2015). A multi-parameter regularization model for image restoration. *Signal Processing*, 114 :131–142. (Cité en page 81).
- Farid, H. and Adelson, E. H. (1999). Separating reflections from images by use of independent component analysis. *JOSA A*, 16(9) :2136–2145. (Cité en page 26).
- Fishler, E., Grosmann, M., and Messer, H. (2002). Detection of signals by information theoretic criteria : General asymptotic performance analysis. *IEEE Transactions on Signal Processing*, 50(5) :1027–1036. (Cité en page 10).
- Galatsanos, N. P. and Chin, R. T. (1989). Digital restoration of multichannel images. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(3) :415–421. (Cité en page 15).
- Gazzah, H., Regalia, P. A., Delmas, J.-P., and Abed-Meraim, K. (2002). A blind multi-

BIBLIOGRAPHIE

- channel identification algorithm robust to order overestimation. *IEEE Transactions on Signal Processing*, 50(6) :1449–1458. (Cit  en page 38).
- Gervais, M. J., Harvey, L. O., and Roberts, J. O. (1984). Identification confusions among letters of the alphabet. *Journal of experimental psychology : Human perception and performance*, 10(5) :655. (Cit  en page 24).
- Giannakis, G. B. and Heath, R. W. (2000). Blind identification of multichannel fir blurs and perfect image restoration. *IEEE Transactions on Image Processing*, 9(11) :1877–1896. (Cit  en pages 16, 18, 34, 35 et 54).
- Goel, S., Verma, A., Goel, S., and Juneja, K. (2015). Ica in image processing : A survey. In *Computational Intelligence & Communication Technology (CICT), 2015 IEEE International Conference on*, pages 144–149. IEEE. (Cit  en page 30).
- Harikumar, G. and Bresler, Y. (1999a). Exact image deconvolution from multiple fir blurs. *IEEE Transactions on Image Processing*, 8(6) :846–862. (Cit  en pages 9, 18 et 34).
- Harikumar, G. and Bresler, Y. (1999b). Perfect blind restoration of images blurred by multiple filters : Theory and efficient algorithms. *IEEE Transactions on Image Processing*, 8(2) :202–219. (Cit  en pages 11, 13, 16, 18, 38 et 42).
- Hassibi, B. and Vikalo, H. (2005). On the sphere-decoding algorithm i. expected complexity. *IEEE transactions on signal processing*, 53(8) :2806–2818. (Cit  en page 57).
- Hore, A. and Ziou, D. (2010). Image quality metrics : Psnr vs. ssim. In *Pattern recognition (icpr), 2010 20th international conference on*, pages 2366–2369. IEEE. (Cit  en page 26).
- Hua, Y. (1996). Fast maximum likelihood for blind identification of multiple fir channels. *IEEE transactions on Signal Processing*, 44(3) :661–672. (Cit  en page 11).
- Hua, Y., Abed-Meraim, K., and Wax, M. (1997). Blind system identification using minimum noise subspace. *IEEE Transactions on Signal Processing*, 45(3) :770–773. (Cit  en pages 11 et 38).
- Hunt, B. and Kubler, O. (1984). Karhunen-loeve multispectral image restoration, part i : Theory. *IEEE transactions on acoustics, speech, and signal processing*, 32(3) :592–600. (Cit  en page 15).
- Hyv rinen, A., Karhunen, J., and Oja, E. (2004). *Independent component analysis*, volume 46. John Wiley & Sons. (Cit  en pages 27, 28, 30, 31 et 32).
- Hyv rinen, A. and Oja, E. (2000). Independent component analysis : algorithms and applications. *Neural networks*, 13(4) :411–430. (Cit  en pages 26 et 30).
- Ichir, M. M. and Mohammad-Djafari, A. (2005). Hidden markov models for wavelet image separation and denoising. In *Acoustics, Speech, and Signal Processing, 2005. Proceedings.(ICASSP'05). IEEE International Conference on*, volume 5, pages v–225. IEEE. (Cit  en page 98).
- Jelinek, F. (1969). Fast sequential decoding algorithm using a stack. *IBM Journal of*

- Research and Development*, 13(6) :675–685. (Cité en page 57).
- Jiao, Y., Jin, Q., Lu, X., and Wang, W. (2016). Alternating direction method of multipliers for linear inverse problems. *SIAM Journal on Numerical Analysis*, 54(4) :2114–2137. (Cité en pages 53, 64, 66, 74, 79, 81 et 83).
- Jutten, C. and Herault, J. (1991). Blind separation of sources, part i : An adaptive algorithm based on neuromimetic architecture. *Signal processing*, 24(1) :1–10. (Cité en page 97).
- Kang, M. G. (1998). Generalized multichannel image deconvolution approach and its applications. *Optical Engineering*, 37(11) :2953–2964. (Cité en pages 15 et 16).
- Katsaggelos, A. K. (2012). *Digital image restoration*. Springer Publishing Company, Incorporated. (Cité en pages 7 et 19).
- Katsaggelos, A. K. and Lay, K.-T. (1991). Maximum likelihood blur identification and image restoration using the em algorithm. *IEEE Transactions on Signal Processing*, 39(3) :729–733. (Cité en page 13).
- Kayabol, K., Kuruoglu, E. E., and Sankur, B. (2009). Bayesian separation of images modeled with mrf's using mcmc. *IEEE Transactions on Image Processing*, 18(5) :982–994. (Cité en page 26).
- Keelan, B. (2002). *Handbook of image quality : characterization and prediction*. CRC Press. (Cité en page 20).
- Koh, K., Kim, S.-J., and Boyd, S. (2007). A method for large-scale l_1 -regularized logistic regression. In *AAAI*, pages 565–571. (Cité en pages 43 et 46).
- Koldovsky, Z., Tichavsky, P., and Oja, E. (2006). Efficient variant of algorithm fastica for independent component analysis attaining the cramer-rao lower bound. *IEEE Transactions on neural networks*, 17(5) :1265–1277. (Cité en page 31).
- Langlois, D., Chartier, S., and Gosselin, D. (2010). An introduction to independent component analysis : Infomax and fastica algorithms. *Tutorials in Quantitative Methods for Psychology*, 6(1) :31–38. (Cité en page 30).
- Lathauwer, L. D. (2011). A short introduction to tensor-based methods for factor analysis and blind source separation. In *2011 7th International Symposium on Image and Signal Processing and Analysis (ISPA)*, pages 558–563. (Cité en page 27).
- Lee, T.-W., Girolami, M., and Sejnowski, T. J. (1999). Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural computation*, 11(2) :417–441. (Cité en page 32).
- Li, L., Wang, R.-L., and Chang, C.-C. (2011). A digital watermark algorithm for qr code. *IJIIP : International Journal of Intelligent Information Processing*, 2(2) :29–36. (Cité en page 78).
- Liu, A., Lin, W., and Narvaria, M. (2012). Image quality assessment based on gradient similarity. *IEEE Transactions on Image Processing*, 21(4) :1500–1512. (Cité en page 78).

BIBLIOGRAPHIE

- Liu, H., Xu, G., and Tong, L. (1994). A deterministic approach to blind identification of multi-channel fir systems. In *Acoustics, Speech, and Signal Processing, 1994. ICASSP-94., 1994 IEEE International Conference on*, volume 4, pages IV–581. IEEE. (Cité en pages 34 et 38).
- Lubin, J. (1995). A visual discrimination model for imaging system design and evaluation. *Vision models for target detection and recognition*, 2 :245–357. (Cité en page 24).
- Mannos, J. and Sakrison, D. (1974). The effects of a visual fidelity criterion of the encoding of images. *IEEE transactions on Information Theory*, 20(4) :525–536. (Cité en page 24).
- McAndrew, A. (2004). *An introduction to digital image processing with matlab notes for scm2511 image processing*. (Cité en page 78).
- Mittal, A., Soundararajan, R., and Bovik, A. C. (2013). Making a “completely blind” image quality analyzer. *IEEE Signal Processing Letters*, 20(3) :209–212. (Cité en page 23).
- Miura, N. and Baba, N. (1995). Segmentation-based multiframe blind deconvolution of solar images. *JOSA A*, 12(9) :1858–1866. (Cité en pages 16 et 17).
- Molina, R., Mateos, J., and Katsaggelos, A. K. (2006). Blind deconvolution using a variational approach to parameter, image, and blur estimation. *IEEE Transactions on Image Processing*, 15(12) :3715–3727. (Cité en page 14).
- Moulines, E., Duhamel, P., Cardoso, J.-F., and Mayrargue, S. (1995). Subspace methods for the blind identification of multichannel fir filters. *IEEE Transactions on signal processing*, 43(2) :516–525. (Cité en page 11).
- Na, W. and Paik, J. K. (1996). Multichannel image restoration based on a pseudo-block-diagonalized wiener filter. In *Proc. 1996 Visual Comm., Image Processing*, volume 2727. (Cité en page 15).
- Naik, G. R. and Kumar, D. K. (2011). An overview of independent component analysis and its applications. *Informatica*, 35(1). (Cité en page 26).
- Neumann, L., Matkovic, K., and Purgathofer, W. (1998). Perception based color image difference. In *Computer Graphics Forum*, volume 17, pages 233–241. Wiley Online Library. (Cité en page 24).
- Oh, J., Woolley, S. I., Arvanitis, T. N., and Townend, J. N. (2001). A multistage perceptual quality assessment for compressed digital angiogram images. *IEEE Transactions on medical imaging*, 20(12) :1352–1361. (Cité en page 24).
- Pai, H.-T. and Bovik, A. C. (2001). On eigenstructure-based direct multichannel blind image restoration. *IEEE Transactions on Image Processing*, 10(10) :1434–1446. (Cité en page 17).
- Pearlmutter, B. A. and Parra, L. C. (1997). Maximum likelihood blind source separation : A context-sensitive generalization of ica. In *Advances in neural information processing systems*, pages 613–619. (Cité en page 31).

- Pedersen, M. and Hardeberg, J. Y. (2009). Survey of full-reference image quality metrics. (Cité en pages 23 et 83).
- Pedersen, M. and Hardeberg, J. Y. (2012). Full-reference image quality metrics : Classification and evaluation. *Foundations and Trends® in Computer Graphics and Vision*, 7(1) :1–80. (Cité en page 20).
- Pham, D., Ghanbarzadeh, A., Koc, E., Otri, S., Rahim, S., and Zaidi, M. (2011). The bees algorithm-a novel tool for complex optimisation. In *Intelligent Production Machines and Systems-2nd I* PROMS Virtual International Conference (3-14 July 2006)*. sn. (Cité en page 19).
- Pham, D. T. and Garat, P. (1997). Blind separation of mixture of independent sources through a quasi-maximum likelihood approach. *IEEE transactions on Signal Processing*, 45(7) :1712–1725. (Cité en page 103).
- Plumbley, M. D. and Oja, E. (2004). A " nonnegative pca" algorithm for independent component analysis. *IEEE Transactions on Neural Networks*, 15(1) :66–76. (Cité en page 27).
- Porat, B. and Friedlander, B. (1991). Blind equalization of digital communication channels using high-order moments. *IEEE Transactions on Signal Processing*, 39(2) :522–526. (Cité en page 13).
- Rissanen, J. (1978). Modeling by shortest data description. *Automatica*, 14(5) :465–471. (Cité en page 10).
- Rudin, L. I., Osher, S., and Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms. *Physica D : Nonlinear Phenomena*, 60(1-4) :259–268. (Cité en page 61).
- Rushmeier, H., Ward, G., Piatko, C., Sanders, P., and Rust, B. (1995). Comparing real and synthetic images : Some ideas about metrics. In *Rendering Techniques' 95*, pages 82–91. Springer. (Cité en page 24).
- Sanei, S. and Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons. (Cité en page 31).
- Schatz, R., Hofffeld, T., Janowski, L., and Egger, S. (2013). From packets to people : Quality of experience as a new measurement challenge. In *Data traffic monitoring and analysis*, pages 219–263. Springer. (Cité en page 21).
- Schulz, T. J. (1993). Multiframe blind deconvolution of astronomical images. *JOSA A*, 10(5) :1064–1073. (Cité en pages 16 et 17).
- Seshadrinathan, K., Soundararajan, R., Bovik, A. C., and Cormack, L. K. (2010). Study of subjective and objective quality assessment of video. *IEEE transactions on Image Processing*, 19(6) :1427–1441. (Cité en page 26).
- Sheikh, H. R. (2003). Image and video quality assessment research at live. <http://live.ece.utexas.edu/research/quality/>. (Cité en page 22).

BIBLIOGRAPHIE

- Sheikh, H. R., Sabir, M. F., and Bovik, A. C. (2006). A statistical evaluation of recent full reference image quality assessment algorithms. *IEEE Transactions on image processing*, 15(11) :3440–3451. (Cité en page 26).
- Shnayderman, A., Gusev, A., and Eskicioglu, A. M. (2004). Multidimensional image quality measure using singular value decomposition. In *Proceedings of SPIE*, volume 5294, pages 82–92. (Cité en page 25).
- Shnayderman, A., Gusev, A., and Eskicioglu, A. M. (2006). An svd-based grayscale image quality measure for local and global assessment. *IEEE Transactions on Image Processing*, 15(2) :422–429. (Cité en page 25).
- Soudene, W., Abed-Meraim, K., and Beghdadi, A. (2005). Deterministic techniques for multichannel blind image deconvolution. *mh*, 1(1). (Cité en page 37).
- Soudene, W., Abed-Meraim, K., and Beghdadi, A. (2009). A new look to multichannel blind image deconvolution. *IEEE Transactions on Image Processing*, 18(7) :1487–1500. (Cité en pages 10, 11, 34 et 52).
- Soudene, W., Aïssa-El-Bey, A., Abed-Meraim, K., and Beghdadi, A. (2007). Blind image separation using sparse representation. In *Image Processing, 2007. ICIP 2007. IEEE International Conference on*, volume 3, pages III–125. IEEE. (Cité en pages 31, 98, 99, 101 et 103).
- Soudene, W., Beghdadi, A., Abed-Meraim, K., and Mouhouche, B. (2004). Regularized mre method for blind multichannel image deconvolution. In *Signals, Systems and Computers, 2004. Conference Record of the Thirty-Eighth Asilomar Conference on*, volume 2, pages 2233–2237. IEEE. (Cité en page 18).
- Srivastava, R., Parthasarthy, H., Gupta, J., and Choudhary, D. R. (2009). Image restoration from motion blurred image using pdes formalism. In *Advance Computing Conference, 2009. IACC 2009. IEEE International*, pages 61–64. IEEE. (Cité en page 19).
- Stockham, T. G., Cannon, T. M., and Ingebretsen, R. B. (1975). Blind deconvolution through digital signal processing. *Proceedings of the IEEE*, 63(4) :678–692. (Cité en page 14).
- Taylor, C. C., Pizlo, Z., Allebach, J. P., and Bouman, C. A. (1997). Image quality assessment with a gabor pyramid model of the human visual system. In *Human Vision and Electronic Imaging*, volume 3016, pages 58–69. (Cité en page 24).
- Teo, P. C. and Heeger, D. J. (1994). Perceptual image distortion. In *Image Processing, 1994. Proceedings. ICIP-94., IEEE International Conference*, volume 2, pages 982–986. IEEE. (Cité en pages 20 et 24).
- Tikhonov, A. N., Arsenin, V. I., and John, F. (1977). *Solutions of ill-posed problems*, volume 14. Winston Washington, DC. (Cité en page 61).
- Tom, B. C., Katsaggelos, A. K., and Lay, K.-T. (1996). Multichannel image identification and restoration using the expectation-maximization algorithm. *Optical Engineering*, 35(1) :241–254. (Cité en pages 12, 16 et 17).

- Tonazzini, A., Bedini, L., and Salerno, E. (2006). A markov model for blind image separation by a mean-field em algorithm. *IEEE Transactions on Image Processing*, 15(2) :473–482. (Cité en page 26).
- Tong, L., Inouye, Y., and Liu, R.-W. (1993). Waveform-preserving blind estimation of multiple independent sources. *IEEE Transactions on Signal Processing*, 41(7) :2461–2470. (Cité en page 97).
- Tong, L., Liu, R.-W., Soon, V. C., and Huang, Y.-F. (1991). Indeterminacy and identifiability of blind identification. *IEEE Transactions on circuits and systems*, 38(5) :499–509. (Cité en pages 28 et 97).
- Tong, L., Soon, V., Huang, Y., and Liu, R. (1990). Amuse : a new blind identification algorithm. In *Circuits and Systems, 1990., IEEE International Symposium on*, pages 1784–1787. IEEE. (Cité en page 29).
- Tong, L., Xu, G., and Kailath, T. (1994). Blind identification and equalization based on second-order statistics : A time domain approach. *IEEE Transactions on information Theory*, 40(2) :340–349. (Cité en page 18).
- Tong, L. and Zhao, Q. (1999). Joint order detection and blind channel estimation by least squares smoothing. *IEEE Transactions on Signal Processing*, 47(9) :2345–2355. (Cité en page 10).
- Torkkola, K. (1999). Blind separation for audio signals-are we there yet? In *First International Workshop on Independent component analysis and blind source separation*, pages 239–244. (Cité en page 100).
- Via, J., Santamaria, I., and Perez, J. (2006). Effective channel order estimation based on combined identification/equalization. *IEEE Transactions on Signal Processing*, 54(9) :3518–3526. (Cité en page 38).
- Wang, Z. and Bovik, A. C. (2006). Modern image quality assessment. *Synthesis Lectures on Image, Video, and Multimedia Processing*, 2(1) :1–156. (Cité en pages 22 et 78).
- Wang, Z. and Bovik, A. C. (2009). Mean squared error : Love it or leave it? a new look at signal fidelity measures. *IEEE signal processing magazine*, 26(1) :98–117. (Cité en page 88).
- Wang, Z. and Bovik, A. C. (2011). Reduced-and no-reference image quality assessment. *IEEE Signal Processing Magazine*, 28(6) :29–40. (Cité en page 23).
- Wang, Z., Bovik, A. C., and Lu, L. (2002). Why is image quality assessment so difficult? In *Acoustics, Speech, and Signal Processing (ICASSP), 2002 IEEE International Conference on*, volume 4, pages IV–3313. IEEE. (Cité en page 25).
- Wang, Z., Bovik, A. C., and Sheikh, H. R. (2005). Structural similarity based image quality assessment. *Digital Video image quality and perceptual coding*, pages 225–241. (Cité en pages vii et 85).
- Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. (2004). Image quality assessment : from error visibility to structural similarity. *IEEE transactions on image*

- processing*, 13(4) :600–612. (Cité en pages 20, 22, 25, 26, 79 et 84).
- Wirawan, I., Abed-Meraim, K., Maître, H., and Duhamel, P. (2003). Blind multichannel image restoration using subspace based method. In *Acoustics, Speech, and Signal Processing, 2003. Proceedings. (ICASSP'03). 2003 IEEE International Conference on*, volume 5, pages V–9. IEEE. (Cité en pages 11 et 38).
- Xue, S.-J. and Wu, W. (2012). Scheduling workflow in cloud computing based on hybrid particle swarm algorithm. *Indonesian Journal of Electrical Engineering and Computer Science*, 10(7) :1560–1566. (Cité en page 19).
- Yeredor, A. (2000). Blind separation of gaussian sources via second-order statistics with asymptotically optimal weighting. *IEEE Signal Processing Letters*, 7(7) :197–200. (Cité en pages 30, 98, 99 et 101).
- Zervakis, M. E. (1992). Optimal restoration of multichannel images based on constrained mean-square estimation. *Journal of Visual Communication and Image Representation*, 3(4) :392–411. (Cité en page 15).
- Zhang, H. and Zhang, Y. (2009). Sparse representation based iterative incremental image deblurring. In *Image Processing (ICIP), 2009 16th IEEE International Conference on*, pages 1293–1296. IEEE. (Cité en page 34).
- Zhang, J., He, K., Zhou, J., and Gong, M. (2011). Image wavelet denoising based on human vision system theory. *International Journal of Advancements in Computing Technology*, 3(5). (Cité en page 78).
- Zhu, Y., Wang, L., and Chai, J. (2009). Multichannel blind image restoration using subspace-based extended cls method. In *Management and Service Science, 2009. MASS'09. International Conference on*, pages 1–4. IEEE. (Cité en page 16).
- Zibulevsky, M. and Pearlmutter, B. A. (2001). Blind source separation by sparse decomposition in a signal dictionary. *Neural computation*, 13(4) :863–882. (Cité en page 98).
- Ziehe, A. and Müller, K.-R. (1998). Tdsep—an efficient algorithm for blind separation using time structure. In *ICANN 98*, pages 675–680. Springer. (Cité en page 29).

Fouad BOUDJENOUIA

Restauration d'images avec critères orientés qualité

Résumé :

Cette thèse concerne la restauration aveugle d'images (formulée comme un problème inverse mal-posé et mal-conditionné), en considérant particulièrement les systèmes SIMO. Dans un premier temps une technique d'identification aveugle de ce système où l'ordre du canal est inconnu (surestimé) est introduite. Nous introduisons d'abord une version simplifiée à coût réduit SCR de la méthode des relations croisées (CR). Ensuite, une version robuste R-SCR basée sur la recherche d'une solution parcimonieuse minimisant la fonction de coût CR est proposée. La restauration d'image est ensuite assurée par une nouvelle approche inspirée des techniques de décodage des signaux 1D et étendue ici aux cas de la restauration d'images en se basant sur une recherche arborescente efficace (algorithme 'Stack'). Plusieurs améliorations de la méthode 'Stack' ont été introduites afin de réduire sa complexité et d'améliorer la qualité de restauration lorsque les images sont fortement bruitées. Ceci en utilisant une technique de régularisation et une approche d'optimisation all-at-once basée sur la descente du gradient qui permet de raffiner l'image estimée et mieux converger vers la solution optimale. Ensuite, les mesures de la qualité d'images sont utilisées comme fonctions de coûts (intégrées dans le critère global) et ce afin d'étudier leur potentiel pour améliorer les performances de restauration. Dans le contexte où l'image d'intérêt est corrompue par d'autres images interférentes, sa restauration nécessite le recours aux techniques de séparation aveugle de sources. Pour cela, une étude comparative de certaines techniques de séparation basées sur la propriété de décorrélation au second ordre et la parcimonie est réalisée.

Mots clés : Identification aveugle du système, Restauration multi-canal d'images, Décodeur séquentiel, Régularisation TV, Amélioration de la qualité d'image, Séparation aveugle d'images, Décorrélation du second ordre, Représentation parcimonieuse.

Images restoration based on quality criteria

Abstract :

This thesis concerns the blind restoration of images (formulated as an ill-posed and ill-conditioned inverse problem), considering a SIMO system. Thus, a blind system identification technique in which the order of the channel is unknown (overestimated) is introduced. Firstly, a simplified version at reduced cost SCR of the cross relation (CR) method is introduced. Secondly, a robust version R-SCR based on the search for a sparse solution minimizing the CR cost function is proposed. Image restoration is then achieved by a new approach (inspired from 1D signal decoding techniques and extended here to the case of 2D images) based on an efficient tree search (Stack algorithm). Several improvements to the 'Stack' method have been introduced in order to reduce its complexity and to improve the restoration quality when the images are noisy. This is done using a regularization technique and an all-at-once optimization approach based on the gradient descent which refines the estimated image and improves the algorithm's convergence towards the optimal solution. Then, image quality measurements are used as cost functions (integrated in the global criterion), in order to study their potential for improving restoration performance. In the context where the image of interest is corrupted by other interfering images, its restoration requires the use of blind sources separation techniques. In this sense, a comparative study of some separation techniques based on the property of second-order decorrelation and sparsity is performed.

Keywords : Blind system identification, Multichannel image restoration, Sequential decoding, TV regularization, Image quality enhancement, Blind image separation, Second order decorrelation, Sparse representation.