

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj

Faculté des Sciences et de la technologie

Département d'Electronique

Mémoire

Présenté pour obtenir

LE DIPLOME DE MASTER

FILIERE : ELECTRONIQUE

Spécialité : Electronique des systèmes embarqués.

Par

Ben hamadi Razika

Intitulé

*Fusion d'image multifocal utilisant la transformation
en ondelettes discrète et le réseau neuronal à
convolution CNN*

Thème dirigé par : Professeur : Messali Zoubaida.

Devant le jury composé de :

Prof à Université de BBA président.

Prof à Université de BBA Examineur.

Prof : Messali Zoubaida Prof à Université de BBA Encadreur.

Année Universitaire 2020/2021

Résumé

Le but de la fusion est l'utilisation des différentes techniques pour la combinaison entre plusieurs images de différentes sources pour obtenir une nouvelle image plus riche en information que l'image initiale.

Les réseaux de neurones convolutionnels sont des réseaux de neurones multicouches qui sont spécialisés pour la classification des images, alors on a proposé trois modèles avec différentes architectures.

La transformée en ondelettes est une technique de représentation temps échelle permet de décomposer une image en sous images dites 'approximation' contenant les basses fréquences et sous images qui contiennent les hautes fréquences et qui indiquent les détails horizontal, vertical et diagonal de l'image.

Le but de ce travail est l'utilisation de transformation en ondelette discrètes et le réseau neuronal à convolution pour faire la fusion focale d'une image d'entrée.

Les mots clés : fusion multifocal, la transformée en ondelettes, réseau neuronal image.

Abstract

The purpose of the merger is the use of different techniques for the combination between several images from different sources to obtain a new image richer in information than the initial image.

Convolutional neural networks are multilayer neural networks that are specialized for the classification of images, so we have proposed three models with different architectures.

The wavelet transform is a time-scale representation technique used to break down an image into so-called 'approximation' sub-images containing low frequencies and sub-images which contain high frequencies and which indicate the horizontal, vertical and diagonal details of the image.

The goal of this work is the use of discrete wavelet transforms and the convolutional neural network to do focal fusion of an input image.

the key words: multifocal fusion, the wavelet transform, neural network, image.

الملخص

الغرض من الدمج هو استخدام تقنيات مختلفة للجمع بين عدة صور من مصادر مختلفة للحصول على صورة جديدة أكثر ثراءً بالمعلومات من الصورة الأولية. الشبكات العصبية التلافيفية هي شبكات عصبية متعددة الطبقات متخصصة في تصنيف الصور ، لذلك اقترحنا ثلاثة نماذج ببنيات مختلفة التحويل النهائي هو تقنية تمثيل بمقياس الوقت تُستخدم لتقسيم الصورة إلى ما يسمى بالصور الفرعية "التقريبية" التي تحتوي على ترددات منخفضة وصور فرعية تحتوي على ترددات عالية والتي تشير إلى التفاصيل الأفقية والعمودية والقطرية للصورة الهدف من هذا العمل هو استخدام التحويلات النهائية المنفصلة والشبكة العصبية التلافيفية للقيام بالاندماج البؤري لصورة الإدخال **الكلمات المفتاحية :** الاندماج متعدد البؤر ، التحويل المويجي ، الشبكة العصبية ، الصورة.

Dédicaces

Je dédie ce mémoire:

À mes très chers parents pour leurs soutien durant toute ma vie d'étude et sans eux je ne serai jamais devenu ainsi.

À mes frères et ma sœur, et à toute ma famille.

À mes amis d'enfance. À mes amis d'étude pour leurs soutien et leurs encouragements.

À tous les professeurs et enseignants qui m'ont suivi durant tout mon cursus universitair et qui m'ont permis de réussir Dans mes études.

À toute personne ayant contribué à ce travail de près ou de loin.

BEN HAMADI RAZIKA

Remerciements

Le grand remerciement revient à Dieu qui m'a donné la force et le courage à réaliser et terminer ce modeste travail.

*Je tiens à remercier très vivement notre encadreur madame **Messali Zoubeida**, Professeur à l'université Mohamed El Bachir El Ibrahimi Bordj Bou Arreridj, je la remercie de m' avoir toujours poussé vers l'avant, pour toute la confiance qu'elle me porte, pour sa grande disponibilité inconditionnelle, ses conseils avisés, et ses encouragements. Ses nombreuses idées furent un soutien très précieux.*

Je remercie mes amis et collègues de l'université, pour l'ambiance conviviale qu'ils ont contribué à entretenir, les bons moments passés en leur compagnie et leur sympathie.

Je remercie également messieurs les membres de jury, d'avoir accepté de jurer ce modeste travail.

A tous ceux qui m' avons eu la chance de travailler avec ou que nous avons eu l'honneur de côtoyer avant et pendant mon mémoire, et à tous mes professeurs de l'Université de Mohamed El Bachir El Ibrahimi Bordj Bou Arreridj.

Enfin, je remercie chaleureusement tous les membres de ma famille et tous mes amis pour leur soutien et leurs encouragements.

Table des Matières

Résumé	
Abstract	
الملخص	
Dédicaces	I
Remerciements	II
Table des matières	III
Liste des figures	
III	
Liste des tableaux	III
Les abréviations	III
III Introduction Générale	
.....	01
Chapitre 1 : FUSION D'IMAGE	
1.1.Introduction.....	02
1.2.Fusion d'image multifocale.....	02
1.3.Types des Systèmes de Fusion d'Images.....	04
1.3.1.Systèmes de Fusion d'Images Mono-Capteur.....	04
1.3.2.Système de Fusion d'Images Multi-Capteurs.....	04
1.4.Classification des Algorithmes de Fusion d'Images.....	05
1.4.1.Classification Selon les Niveaux de Fusion.....	05
1.4.2.Classification Selon le Type des Images d'Entrée.....	07
1.4.3.Classification Selon le Domaine de Fusion.....	07
1.5. Domaines d'application de la fusion.....	08
1.6Critères d'Evaluations d'Algorithme De Fusion d'Images Multifocale.....	10
1.7Règles de fusion d'image.....	12
1.8. Conclusion.....	10
Chapitre 2 : RESEAUX DE NEURONE CONVOLUTIONNEL ET LA TRANSFORMEE EN ENDELLETTE DISCRETE	
2.1.Introduction.....	14
2.2.Réseau de neurones.....	14
2.2.1. Réseau de neurone artificiels.....	14

2.2.2. Applications des réseaux de neurones.....	15
2.2.3. Réseaux de neurone convolutionnels.....	15
2.2.3.1. Explication d’algorithme de réseau de neurone covolutionnel.....	18
2.2.3.2. Application d’algorithme CNN sur une image.....	23
2.2.3.3. Évaluation des methodes.....	24
2.3.Transformée en ondelettes.....	27
2.4.Fusion d’images Dans Le Domaine de Transformée En Ondelettes.....	28
2.4.1.Règles de Fusion dans le Domaine d’Ondelettes.....	28
2.4.Conclusion.....	29
Chapitre3 : APPLICATION D’UN ALGORITHME DE FUSION D’IMAGE MULTIFOCAL EN UTILISANT CNN ET DWT	
3.1.Introduction.....	30
3.2.Résultats et Discussions.....	30
3.2.1. Logiciel MATLAB.....	30
3.2.2. Nature de Données.....	30
3.2.3. Fusion d’Images Multifocale Dans Le Domaine Spaciale.....	31
3.2.3.1. Calcule de Critère D’Evaluation.....	32
3.2.4. Résultats Des Algorithmes Conventionnels De Fusion d’Images à Base De DWT.....	33
3.2.4.1.L’organigramme	33
3.2.4.2.Résultats et Discussions.....	34
3.2.4.3.Evaluation de performance.....	35
3.2.5. Résultats des algorithmes conventionnels de fusion d’images à base de CNN.....	35
3.2.5.1. L’organigramme.....	35
3.2.5.2. Résultats et Discussions.....	36

3.2.6.Implémentation des Algorithmes de Fusion d'Images à Base de CNN dans le domaine de DWT.....	37
3.2.6.1.L'organigramme.....	37
3.2.6.2.Résultats et Discussions.....	37
3.3.Comparaison des résultats obtenus.....	37
3.4. Conclusion.....	38
Conclusion Générale.....	39
Références Bibliographiques	40

Liste des figures

Chapitre 1 : fusion d'image.

Figure.1.1. Diagramme générique d'un système de fusion de données.....	0 3
Figure 1.2. Schéma bloc générale d'un système de fusion d'images multimodales...03	
Figure 1.3. Systèmes de Fusion d'Images Mono-Capteur.....	04
Figure 1.4. Système de fusion d'images multi-capteurs.....	05
Figure.1.5. Niveaux de traitements de la fusion d'images.....	06
Figure 1.6. Illustration de la fusion dans le domaine spatial et dans le domaine transformées.....	07
Figure.1.7. Schéma général de l'algorithme VIF.....	11

Chapitre 2 : Réseaux de neurone convolutionnel et la transformée en endellette discrète .

Figure 2 .1. Principe d'un réseau de neurones artificiels.....	15
Figure .2.2. Différence entre CNN et Machine Learning Traditionnel pour l'analyse d'images.....	17
Figure .2.3. Fonctionnement des couches d'un réseau CNN.....	17
Figure.3.4. Réseau de neurone convolutionnel.....	18
Figure.2.5. Les étapes d'algorithme de réseau de neurone convolutionnel.....	19
Figure.2.6. L'opération de convolution au niveau de couche de convolution.....	20
Figure.2.7. La fonction d'activation R_eLU	20
Figure.2.8. Illustration de l'ensemble convolution et activation.....	21
Figure.2.9. Exemple d'une opération de pooling de taille 2×2	22

Figure.2.10. Illustration de l'étape de "flattering".....	23
Figure.2.11. Application d'un algorithme CNN.....	23
Figure.2.12. Niveaux de décomposition en ondelettes.....	27
Figure.2.13. Fusion de deux images à l'aide de transformées en ondelettes.....	28

Chapitre 3 :Application d'un algorithme de fusion d'image multifocal en utilisant CNN et DWT.

Figure.3.1. Ensemble des images monofocus originales de test utilisées.....	31
Figure 3.2. les étapes de l'algorithme de fusion.....	32
Figure 3.3. Fusion d'images multi-focus.....	32
Figure.3.4. Processus générale de fusion d'images par la transformée en Ondelettes.	34
Figure.3.5. Résultats visuels de fusion pour la fusion multifocale par la transformée en Ondelette discrète.....	35
Figure.3.6. Processus générale de fusion d'images par la méthode de réseau de neurone convolutionnel.....	36
Figure.3.7. Résultats visuels de fusion pour la fusion multifocale par la méthode de neurone convolutionnel.....	37
Figure.3.8. Processus générale de fusion d'images par la méthode de réseau de neurone convolutionnel et la transformée en ondelette discrète.....	37

Liste des tableaux

Chapitre 2 : Réseaux De Neurones Convolutionnel Et La Transformée En Ondelette Discrète

Tableau 2.1. Matrice de confusion des prédictions d'un classifieur à C classes.....24

Tableau.2.2. La matrice de confusion.....25

Chapitre 3 :Application d'Un Algorithme De Fusion d'Image Multifocal En Utilisant CNN Et DWT.

Tableau 3.1.Evaluation des performances des méthodes de fusion dans le domaine spatial en fonction des règles de fusion, image "multi focus (non bruitées).....33

Tableau 3.2.Evaluation des performances de la méthode de fusion DWT en fonction de l'ondelette d'analyse, image "multifocus.....35

Liste des abréviations

- **AL**: Absolue Maximale.
- **BR** :Basse Résolution.
- **CNN** : Convolutional Neural Network.
- **DWT** : Discrete Wavelet Transform.
- **ECG** : L'Electrocardiogramme.
- **EN** :Entropie.
- **FFT** : Fast Fourier Transform.
- **FN** :Faux Négatifs ou False Negative.
- **FP**:Faux Positifs ou False Positive.
- **FSSIM**:Fusion Structural Similarity Based Image Quality Measurement.
- **Max**:Maximum.
- **Min**:Minimum.
- **HR** :Haute Résolution .
- **MLP** : Perceptron Multi-Layer.
- **NSS** :Natural Scene Statistics.
- **RBF** :Radial Basis Fonction.
- **ReLU**:Rectified Linear Unit.
- **SNR** :Signal to Noise Ratio.
- **Std** : Déviation Standard.
- **SVH** :Système Visuel Humain.
- **TN**:True Negative.
- **TO**:Transformée d'Ondelettes.
- **TP**:True Positive.
- **VIF** :Visual Information Fidelity.
- **VN** :Vrais Négatifs.
- **VP** :Vrais Positifs.

Introduction générale

La fusion de données a été appliquée depuis déjà quelques années dans le domaine du traitement du signal, de l'automatisme et de la prise de décision. Très tôt, avec le développement de nouvelles et nombreuses méthodes d'imagerie, l'idée de combiner les différentes images d'un même objet ou d'une même scène est apparue intéressante et utile, dans de nombreux domaines d'application.

La plupart des concepts utilisés en intelligence artificielle (IA) proviennent ou sont inspirés des recherches en neurosciences. Le concept de **réseau neuronal**, ou de couches de neurones, est issu de la compréhension de l'organisation du cortex cérébral en particulier du cortex visuel du chat.

La fusion d'images associée à l'analyse par ondelettes a également contribué à améliorer les performances des algorithmes de la fusion d'images. La transformée en ondelettes est une solution, elle permet d'avoir la taille de la fenêtre variable. Au lieu de représenter un signal comme la somme pondérée de sinusoides, nous avons la somme pondérée d'ondes translatées et dilatées dans le temps. Bien évidemment, les applications de la transformée en ondelettes sont très vastes elle est appliquée d'une manière générale dans la plupart des applications reposant sur l'analyse d'images.

L'objectif de notre travail est d'étudier une catégorie des algorithmes de fusion d'images, à savoir l'image multifocus. Dans notre étude, nous mettrons l'accent sur l'utilité de la transformée en ondelettes associée à l'analyse multirésolution. Nous essayons également d'implémenter ces algorithmes à base de réseaux de neurones convolutionnels.

Organisation du mémoire :

Pour présenter notre travail, nous avons organisé ce présent manuscrit en trois chapitres, une introduction générale, une conclusion générale et une bibliographie.

Le but général de ce travail est d'établir une étude comparative des algorithmes de fusion d'images multifocal dans le domaine e transformée en ondelettes. Pour cela nous avons utilisé la modélisation de la connaissance par la méthode la discret wavelet transform (DWT) et les réseaux de neurones convolutifs (CNN), qui présentent l'avantage de pouvoir modéliser de manière fine l'imprécision et l'incertitude d'une information apportée par les images.

Après cette introduction générale, nous passons au premier chapitre qui englobe les généralités et notions de base sur la fusion de données dans le domaine d'imagerie et leurs types. Enfin, nous représenterons l'utilisation de fusion multifocale pour fusionner les images.

Dans le deuxième chapitre, nous présentons deux outils utilisés en fusion d'images multifocus: les réseaux de neurones convolutifs et la transformées en ondelette discrète. Dans la première partie de ce chapitre, nous présenterons le fonctionnement les reseaux de neurones artificiels, puis nous passerons à étudier en détail les réseaux de neurone convolutionnel (CNN). La deuxième partie présentera la transformées en ondelettes discrète.

Le troisième chapitre est consacré à la description de l'implémentation des algorithmes de fusion d'images multifocale d'images, nous présenterons une explication des algorithmes de CNN et DWT. Les résultats expérimentaux sont présentés et discutés dans ce chapitre.

Une conclusion générale qui contient une évaluation des travaux effectués et les perspectives est donnée à la fin de ce manuscrit.



**Chapitre 1: Concepts de Base de
la Fusion d'Image.**

1.1 Introduction

La présence d'images numériques dans des applications diverses est plus importante de jour en jour. Cela est dû au développement des systèmes d'acquisitions d'images. La fusion d'images est conçue pour combiner les images partiellement focalisées en une seule image entièrement fusionnée, ce qui devrait être plus informatif pour la perception humaine ou mécanique [1]. L'idée de combiner les différentes images d'un même objet ou d'une même scène est apparue intéressante et utile, dans de nombreux domaines d'application [2]. Les objectifs les plus communs de la fusion d'images sont :

- Netteté de l'image.
- Amélioration de la précision radiométrique.
- Création d'ensembles stéréo de données.
- Augmentation des caractéristiques.
- Amélioration de la classification.
- Détection de changement dans le temps.
- Franchissement des écarts[2].

Nous consacrons ce Chapitre à la présentation des notions liées à l'image et la fusion d'images, (historique, domaine d'application, principe et objectif de fusion).

1.2 Fusion d'Image

Le terme "fusion de données" est largement employé pour caractériser toute combinaison de données. La fusion de données constitue un cadre formel dans lequel s'expriment les moyens et techniques permettant l'alliance des données provenant de sources diverses. Elle vise à l'obtention d'information de plus grande qualité ; la définition exacte de "plus grande qualité" dépendra de l'application. ». Il peut s'agir de la fusion :

- d'une même information vue par différents observateurs.
- de plusieurs informations vues par un seul observateur.
- de plusieurs informations vues par plusieurs observateurs [3].

La Figure 1.1 illustre les différents blocs d'un système de fusion de données.

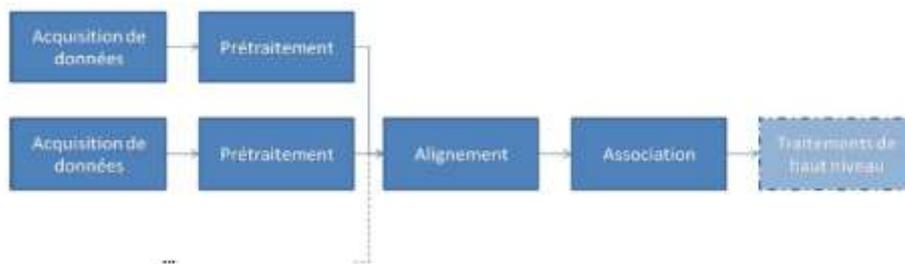


Figure 1.1. Diagramme générique d'un système de fusion de données[3].

D'une manière générale, La fusion d'images est la combinaison de deux ou de plusieurs images issues de différents capteurs afin de créer une nouvelle image contenant le maximum d'informations afin d'améliorer leurs interprétations thématiques [4]. Elle permet de produire une nouvelle image qui conserve une partie de l'information contenue dans chacune des images originales. L'objectif est ainsi de créer une synergie, c'est-à-dire d'obtenir une image fusionnée géométriquement et/ou sémantiquement plus riche qu'une image initiale[2]. Le système de fusion d'images multimodales est similaire au système de fusion de données comme c'est illustré dans la Figure 1.2.

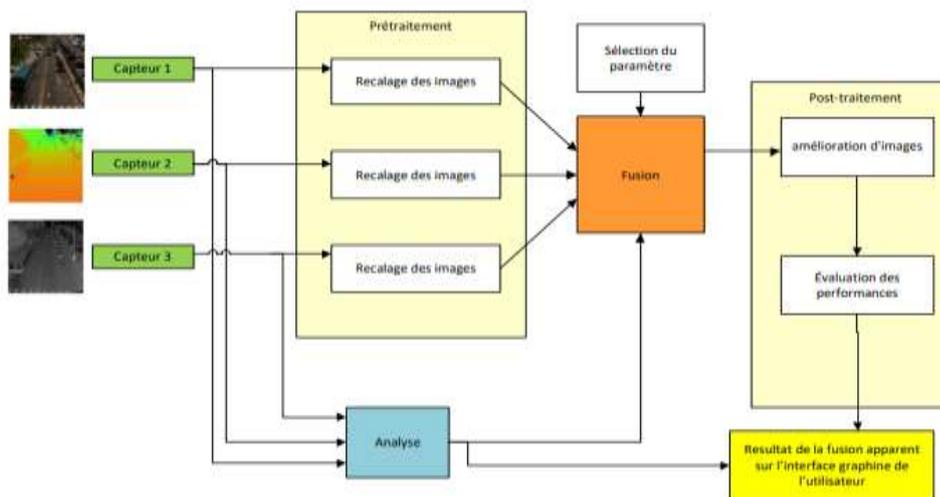


Figure 1.2. Schéma bloc générale d'un système de fusion d'images multimodales[5].

Un seul capteur avec différents modes d'acquisition ou plusieurs capteurs d'imagerie sont déployés dans ce système, ce qui produit des représentations différentes du même objet. Les données recueillies sont d'abord prétraitées; une opération de filtrage peut être appliquée pour éliminer les bruits introduits durant le processus d'acquisition d'images. Une deuxième étape importante du processus de prétraitement est le recalage d'images, c'est-à-dire que les pixels correspondant aux images d'entrée doivent être alignés

géométriquement. Ces images peuvent avoir une translation, une rotation, un désalignement et d'autres transformations géométriques entre elles à cause de processus d'acquisition. En fait, les transformations géométriques sont introduites par plusieurs facteurs[5].

De nombreuses méthodes sont capables de réaliser une fusion d'images. Elles diffèrent par la manière selon laquelle elles favorisent telle ou telle caractéristique des images originales[2].

1.3.Types des Systèmes de Fusion d'Images

1.3.1.Systèmes de Fusion d'Images Mono-Capteur

La Figure 1.3 montre un système de fusion mono capteur.

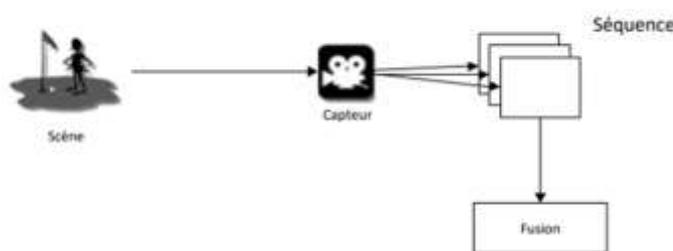


Figure 1.3. Systèmes de Fusion d'Images Mono-Capteur[6].

Le capteur montré effectue l'acquisition de la scène ou l'objet observé comme une séquence d'images. Des informations utiles de ces séquences d'images sont intégrées dans une seule image par le processus de fusion, ce qui permet à un opérateur humain ou à un ordinateur de les exploiter pour effectuer une tâche précise[7].

1.3.2. Système de Fusion d'Images Multi-Capteurs

La Figure 1.4 illustre un système de fusion d'images multimodales

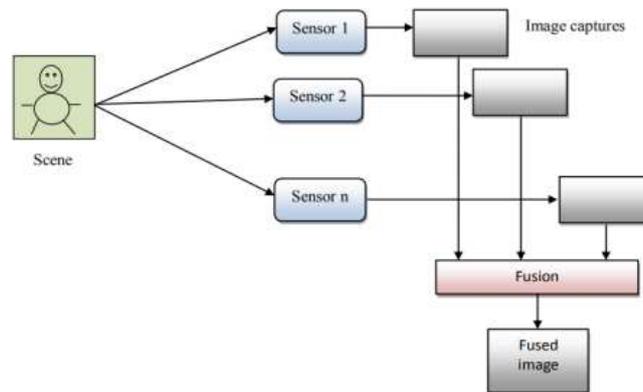


Figure 1.4. Système de fusion d'images multi-capteurs[6].

Pour surmonter les limitations des systèmes de fusion mono-capteur, les systèmes de fusion d'images multi-capteurs consistent à déployer plusieurs capteurs

Parmi les avantages de la fusion d'images multi-capteurs, nous citons:

- 1. Large gamme de fonctionnement :** l'utilisation des capteurs multimodaux dans un système de fusion d'images augmente la portée de fonctionnement. Les capteurs visible et infrarouge peuvent être utilisés pour un fonctionnement jour / nuit.
- 2. Incertitude réduite:** La fusion des informations provenant de capteurs multimodaux peut réduire l'incertitude associée au processus de détection dans chaque capteur.
- 3. Meilleure fiabilité:** la fusion de multiples mesures peut réduire le bruit et donc améliorer la fiabilité de la quantité mesurée.
- 4. Performances robustes du système :** du fait que le système de fusion sollicite plusieurs capteurs, ça permet de corriger et compléter les informations et les données d'un seul capteur.
- 5. La représentation compacte de l'information :** la fusion conduit à des représentations compactes[6].

1.4. Classification des Algorithmes de Fusion d'Images

1.4.1. Classification Selon les Niveaux de Fusion

1. Niveaux de la fusion d'images

Fusion d'image multifocal utilisant la transformation en ondelettes discrètes et le réseau neuronal à convolution CNN .

La fusion d'images peut être effectuée de trois manières selon l'information ou le niveau considérée dans l'image (Figure.1.5). Soit au niveau soit du pixel (fusion bas niveau), soit au niveau des caractéristiques (fusion de moyen niveau), soit au niveau de décision (ou fusion haut niveau).

La fusion de bas niveau fonctionne dans le domaine spatial, le contenu de l'information liée à chaque pixel est déterminé à partir d'un ensemble de pixel dans l'image source. Dans la fusion moyenne niveau, les informations à fusionner sont les caractéristiques extraites sur les images sources qui correspondent à des attributs de texture ou les contours. Quand au niveau haut, les informations à fusionner sont des images d'entrée qui seront traitée individuellement pour l'extraction de l'information[2].

➤ Il y a trois niveaux principaux de la fusion

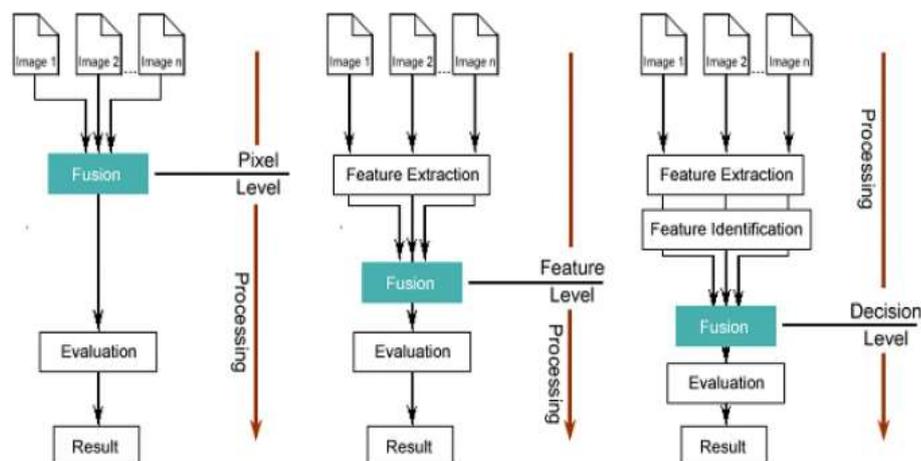


Figure. 1.5. Niveaux de traitements de la fusion d'images[4].

2. La fusion au niveau de pixel

Pour effectuer la fusion au niveau du pixel, les capteurs doivent être identiques (par ex., plusieurs caméras infrarouges) ou commensurables (par ex., images infrarouges et images radar) .

3. La fusion au niveau de fonctionnalité

Pour la fusion au niveau des caractéristiques, un vecteur d'attributs est extrait à partir de la sortie de chaque capteur. Ces vecteurs d'attributs sont ensuite combinés (fusionnés) et une déclaration d'identification est ensuite effectuée sur la base de ce vecteur conjoint.

Les outils utilisés pour la déclaration d'identification comprennent les techniques statistiques (par ex., analyse de regroupements), les réseaux de neurones, les techniques structurales et à base de connaissances.

4. La fusion au niveau de décision

Dans la fusion au niveau des décisions (ou niveau des déclarations), chaque capteur effectue de façon indépendante un estimé ou une déclaration de la scène observée. Ces estimations sont ensuite combinées via un procédé de fusion. Les techniques de fusion de déclarations incluent les méthodes de votation, l'inférence bayésienne et la théorie de Dempster-Shafer (Théorie de l'évidence) [4].

1.4.2. Classification Selon le Type des Images d'Entrée

Les schémas de fusion d'images peuvent être aussi classés selon le type des images d'entrée. Ces bases de données (pour les images médicales) fournissent des images à des fins éducatives et de recherche.

1.4.3. Classification Selon le Domaine de Fusion

En générale, les algorithmes de fusion d'images peuvent être réalisés soit dans le domaine spatial soit dans le domaine de transformées, comme montré dans la Figure 1-6[5].

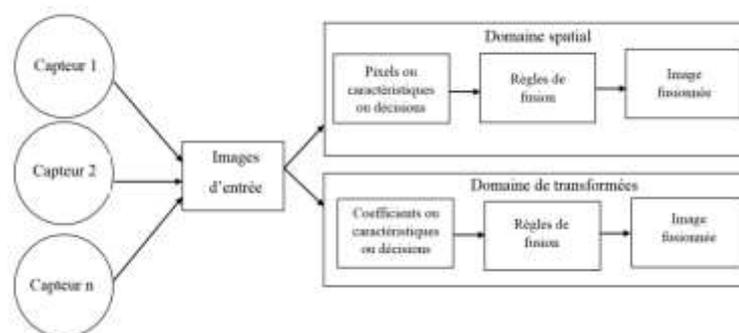


Figure 1.6. Illustration de la fusion dans le domaine spatial et dans le domaine transformées [5].

Dans le domaine spatial

Les pixels ou les régions des images sources sont directement fusionnées par une combinaison linéaire ou non linéaire. Pour ce faire, la fusion des images sources (pixels) est achevée en calculant des poids en fonction de certaines mesures d'importance, qui seront appliqués directement sur les pixels individuels ou sur les voisinages des pixels.

La méthode la plus simple pour fusionner les images multimodales est l'application de la moyenne entre les valeurs des pixels des images sources. Cette méthode conduit cependant à des effets indésirables tels qu'un contraste réduit [7]. Une autre méthode de fusion d'images plus robuste est la moyenne pondérée. Dans cette méthode, la valeur du pixel fusionné est calculée sur la base d'une moyenne pondérée des valeurs du groupe de pixels sources correspondants. L'analyse en composantes principales (ACP) et l'analyse en composante indépendante (ICA). Ces méthodes sont simples, rapides et faciles à implémenter, mais souffrent de problèmes de contraste faible et de perte d'informations[8].

Dans le domaine de transformée

Les méthodes de fusion du domaine spatial conduisent souvent à l'absence d'informations spectrales et à l'introduction de distorsions spatiales. Ces méthodes souffrent d'une faible directionnalité, l'absence de l'information de phase et sont non-invariantes par translation [9]. Ces inconvénients ont été surmontés avec l'utilisation de méthodes de fusion dans le domaine de transformées.

Les algorithmes proposés dans le domaine de transformée sont développés dans la littérature pour remédier aux limitations des méthodes du domaine spatial. La plupart de ces méthodes sont associées à l'analyse multirésolution. Parmi les méthodes de fusion les fréquemment utilisées: les transformées en ondelettes, les transformées en contourlet, les transformées curvelettes et d'autres transformées.

Dans la fusion basée sur une représentation pyramidale, les images d'entrée sont transformées (décomposées) en images de différentes résolutions, c'est une décomposition sous forme d'arbre, de sorte que l'étage supérieur puisse être restitué à partir de l'étage inférieur. Le processus de fusion crée alors une nouvelle pyramide fusionnée à partir des images d'entrée en utilisant une règle de fusion. L'image fusionnée est finalement reconstruite en effectuant une transformée multirésolution inverse[5].

1.5 Domaines d'Application de La Fusion

La fusion d'images trouve sa place dès lors que plusieurs acquisitions du même «objet» (au sens large) sont effectuées et sont à analyser.

Imagerie aérienne et satellitaire

C'est le premier domaine où les méthodes de fusion numérique d'images ont été mises en place. Les premières applications furent militaires. La fusion a été développée pour permettre la reconnaissance d'objets, la poursuite de cibles ou encore la surveillance du champ de bataille. Le commandant en chef dispose de nombreuses sources d'informations (radar, laser, infrarouge, visible...). Le but de la fusion est de combiner de manière rapide et sûre toutes ces informations de manière à offrir au stratège une aide à la décision.

D'autres applications de la fusion d'images ont vu récemment le jour du fait du développement des techniques d'imagerie par satellite et par avion. Ces images sont souvent multi spectrales, c'est-à-dire que le satellite est capable de fournir des images de la même zone géographique, mais acquises dans des conditions différentes avec des capteurs différents. Citons par exemple les canaux XS1, XS2, et XS3 du satellite SPOT qui permet d'accéder de manière assez simple à des images susceptibles d'être fusionnées. Les applications de la fusion en imagerie satellitaire et aérienne permettent d'automatiser un certain nombre de tâches en climatologie, en prédiction des récoltes....

Imagerie médicale

Dans le domaine médical, le médecin à sa disposition un nombre croissant d'images, issues de modalités d'imagerie différentes (imagerie par rayons X, par ultrasons, par résonance magnétique, par émission de positons, ou encore imagerie nucléaire). Il s'agit pour lui de synthétiser toutes ces informations afin d'établir un diagnostic le plus fiable, le plus précis et le plus exact possible. En général, il les compare et les intègre mentalement pour se forger une représentation mentale de l'organe étudié afin de prendre sa décision. Pourtant, les conditions de comparaison de ces images sont souvent difficiles, car ces images n'ont pas forcément la même taille, ni la même résolution spatiale, ni le même contraste, et ne représentent pas forcément l'organe sous le même point de vue. De plus, de par la nature physique de cette imagerie, les structures visualisées dans les images peuvent avoir des représentations bien différentes.

Imagerie industrielle

Dans le domaine de l'industrie, et plus particulièrement en contrôle non destructif, on commence de plus en plus à utiliser différents types de modes de contrôle pour détecter de manière systématique les défauts. L'opérateur se retrouve alors dans la même situation que le médecin, avec souvent une contrainte de temps réel supplémentaire. La plupart des applications consiste à détecter des défauts dans des pièces métalliques, et les imageries

utilisées sont le plus souvent la radiographie sur film, la radioscopie numérique, les ultrasons et le contrôle par courants de Foucault. Les méthodes de fusion sont mises en place pour des pièces très précises dont il faut améliorer la fiabilité et la rapidité de contrôle[2].

Images multifocales

Dans les applications d'appareils photo numériques, lorsqu'un objectif se concentre sur un sujet à une certaine distance, tous les sujets situés à cette distance ne sont pas très nets. Un moyen possible de résoudre ce problème est la fusion d'images, dans laquelle on peut acquérir une série d'images avec différents réglages de mise au point et les fusionner pour produire une image unique avec une profondeur de champ étendue. Le but de ce type de fusion est d'obtenir une seule image tout en focus. Nous nous intéressons à ce type de fusion dans notre travail de master.

L'une des catégories de fusion d'images c'est Images multifocales. Dans les applications d'appareils photo numériques, lorsqu'un objectif se concentre sur un sujet à une certaine distance, tous les sujets situés à cette distance ne sont pas très nets. Un moyen possible de résoudre ce problème est la fusion d'images, dans laquelle on peut acquérir une série d'images avec différents réglages de mise au point et les fusionner pour produire une image unique avec une profondeur de champ étendue. Le but de ce type de fusion est d'obtenir une seule image tout en focus[1].

1.6 Critères d'Évaluations d'Algorithme De Fusion d'Images Multifocale

1.6.1 Entropie(EN)

De l'Information IE En Anglais Information Entropy est un critère qui mesure le degré d'information dans l'image, plus l'IE est grand, plus l'image diffuse d'information

$$EN = - \sum_{i=0}^{L-1} P_f(i) \log_2 P_f(i) \quad (1.1)$$

Avec P_f le rapport du nombre de pixels avec la valeur de niveau de gris a_i sur le nombre total de pixels.

1.6.2 L'écart-type (mesure de qualité (std))

La STD est la racine carrée de la variance (écart-type), la variance d'une image reflète le degré de dispersion entre les valeurs des niveaux de gris et les valeurs moyennes des niveaux de gris, plus la STD est grande, plus il ya de dispersion.

$$STD = \sqrt{\frac{\sum_{i=0}^{N-1} \sum_{j=0}^{M-1} P(i,j)}{NM}} \quad (1.2)$$

Information Mutuelle(Mutual Information MI Compare entre l'image source et l'image fusionnée ,plus la valeur est petite plus la relation entre les 2 images est inexistante.

$$MI = \sum_{af} P_{aF}(a, f) \log \frac{P_{AF}(a,f)}{P_A(a)P_f(f)} \quad (1.3)$$

Avec $P_{AF}(a, f)$ l'histogramme conjoint de l'image fusionné F et l'image source A [10] .

1.6.3 Visual Information Fidelity (VIF)

Est une métrique d'évaluation de la qualité d'image de type référence (FullReference). Elle est basée sur des statistiques de scènes naturelles (Natural Scene Statistics NSS) et la notion d'information d'image extraite par le système visuel humain (SVH). La qualité visuelle de l'image déformée doit se rapporter à la quantité d'informations extraite par le SVH de l'image test par rapport aux informations de l'image référence. Si la quantité d'informations extraite est proche de l'information d'image de référence, la qualité visuelle de l'image déformée est très élevée car aucune perte d'information ne s'est produite dans le canal de distorsion comme c'est illustré sur a Figure 1.7. La valeur de VIF est obtenue par la division des deux mesures d'information.

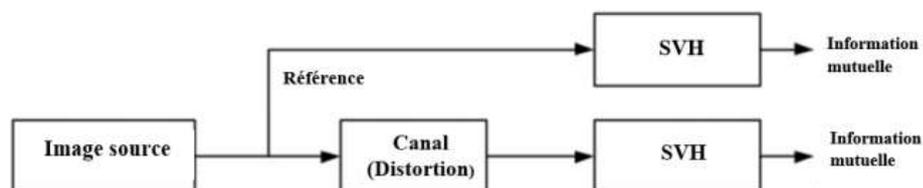


Figure.1.7.Schéma général de l'algorithme VIF[5].

1.6.4 Rapport Signal sur Bruit (SNR)

Le rapport signal/bruit S/B (Signal to Noise Ratio S/N ou SNR en anglais), appelé encore rapport signal à bruit, permet de mesurer la qualité d'un canal de transmission. C'est un nombre sans unité qui est d'autant plus

Grande que le bruit est négligeable .On le calcule à l'aide de l'une ou de l'autre des formules représentées ci-contre:

Formule n°1

$$\frac{S}{B} = \frac{P_S}{P_B} \quad (1.4)$$

Ps : puissance du signal en W

PB : puissance de bruit en W

Formule n°2

$$\frac{S}{B_{dB}} = 10 \log \left(\frac{S}{B} \right) \quad (1.5)$$

Comme la valeur de S/B peut être très grande, on préfère souvent exprimer le rapport S/B en décibels.

1.6.5 Fusion structural similarity based image quality measurement (fssim)

Mesure de la qualité visuelle est importante pour de nombreuses images et applications de traitement vidéo.

Le but de la recherche sur l'évaluation de la qualité est de concevoir des algorithmes qui permettent d'évaluer automatiquement la qualité des images ou des vidéos d'une manière perception cohérente[5].

1.7 Règles de fusion d'images

1.7.1 La Méthode De Maximum

Cette règle de fusion appelée encore règle de remplacement par le pixel maximale ou de règle de fusion absolue maximale (AM).

Dans le domaine de la Transformée en Ondelette, cette règle consiste à sélectionner le coefficient de détail dans chaque sous-bande avec la plus grande amplitude. Les images de source d'entrée sont décomposées en utilisant la transformée en ondelettes discrète (LL, LH, HL, HH bandes).

1.7.2 Méthode de Minimum

Cette méthode est similaire à la méthode de sélection maximale, mais avec la différence, elle considère à sélectionner le pixel avec une valeur de plus faible intensité et ignore toutes les autres valeurs. Cette méthode a aussi l'inconvénient de considérer soit complètement une dénonciation ou rejetant complètement.

1.7.3 La Méthode Moyenne

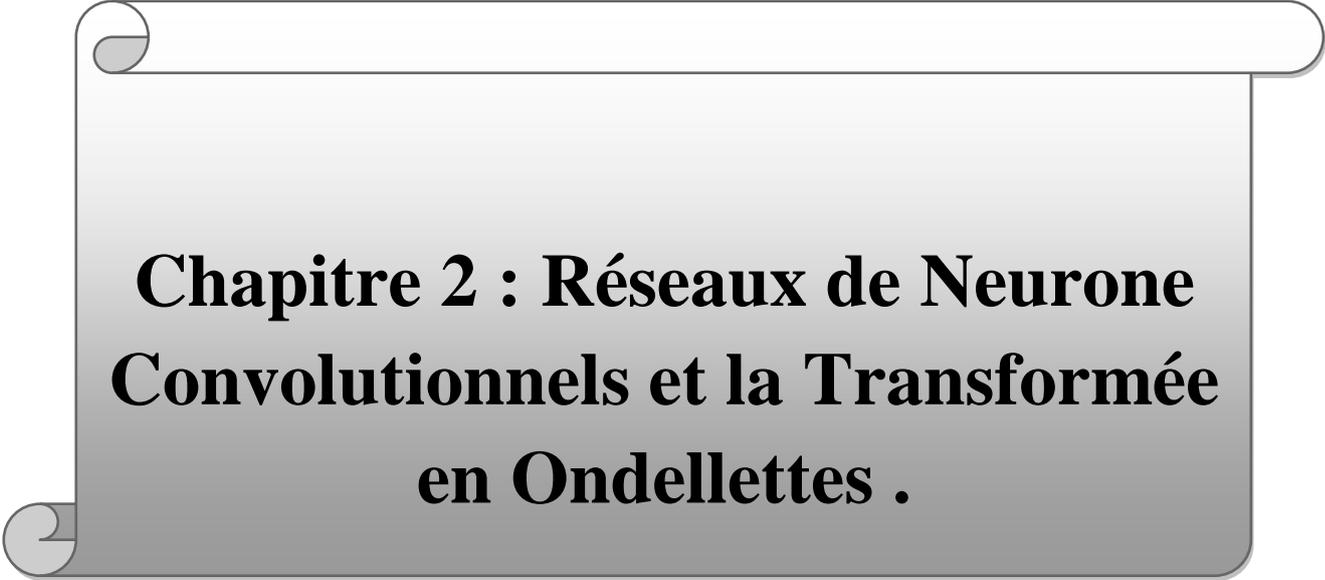
C'est l'approche la plus simple, dans laquelle, l'intensité du pixel de sortie est l'intensité moyenne de tous les pixels correspondants des images d'entrée. En raison de l'opération en moyenne, à la fois le bon et le mauvais renseignement sont réduits au minimum, en arrivant à une image moyenne[11].

1.8 Conclusion

Dans ce chapitre Nous avons présenté un aperçu sur un domaine bien particulier du traitement d'images qui est celui de la fusion d'images. La fusion d'images apparait indispensable dans certaines applications. Ceci explique le foisonnement des techniques utilisées dans la fusion [2].

Le chapitre explique en détail sur trois grandes titres : les concepts de fusion d'images d'images, le système de fusion d'images (notion, types, classification, applications...)et finalement une la fusion des image focaux.

Nous allons aborder au prochain chapitre en détail deux méthodes utilisées à la usion d'images multifocale .



**Chapitre 2 : Réseaux de Neurone
Convolutionnels et la Transformée
en Ondellettes .**

2.1 Introduction

Dans la fin des années 80 Yan le Cun a développé un type de réseau particulier qui s'appelle le réseau de neurone convolutionnel, ces réseaux sont une forme particulière de réseau neuronal multicouche dont l'architecture des connexions est inspirée du cortex visuel des mammifères [12].

D'une autre part la transformée en ondelettes a montré son succès en traitement d'images en différentes application y compris la fusion d'images.

Dans ce qui suit nous présenterons les concepts de base des réseaux de neurones. Nous rappellerons également la transformée en ondelettes.

2.2 Réseau de neurones

2.2.1 Réseau de neurone artificielle

La plupart des algorithmes d'apprentissage profond reposent sur des modèles appelés réseaux de neurones artificiels. Il existe de nombreuses variantes de ces réseaux qui ont été adaptées pour des problématiques spécifiques, et, par simplicité, les éléments communs seront présentés dans cette section. Par la suite, un type de modèle très utilisé sera présenté : les réseaux de neurones convolutifs (convolutional neural network CNN).

Avant de présenter le fonctionnement d'un réseau de neurones, intéressons-nous à l'anatomie d'un réseau de neurones artificiels. Dans sa forme la plus simple, le plus petit élément d'un réseau est le neurone. Il prend la forme de plusieurs nœuds entrants qui sont connectés à un nœud de sortie. Un poids est associé à chaque nœud entrant permettant de calculer une somme pondérée en multipliant chaque poids par la valeur des nœuds entrant. Le résultat de cette somme est transmis à une fonction d'activation qui va calculer la valeur de sortie de ce neurone.

La valeur de sortie de ce neurone est ensuite transmise à un autre neurone.

On peut définir mathématiquement le réseau de neurones comme une fonction f paramétrée par des poids w tel que :

$$fw(x) = y.$$

Il est composé d'une couche de données en entrée connectée à une couche cachée qui contient un certain nombre de neurones qui est connectée à son tour à une couche de sortie. Ceci a évolué vers un Perceptron multi-couche (MLP). La Figure 2.1 illustre les couches d'un réseau de neurones.

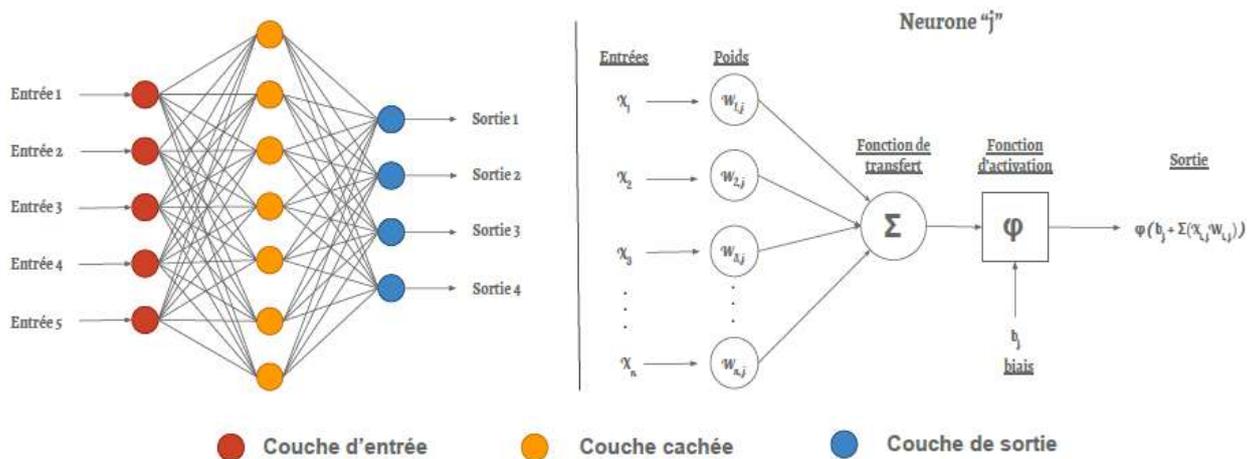


Figure.2.1. Principe d'un réseau de neurones artificiels [13].

La fonction d'activation est un élément essentiel aux réseaux de neurones. Elle introduit une non-linéarité dans le modèle et permet d'étendre la dimension de l'espace des hypothèses. Sans cette fonction d'activation, le modèle pourrait seulement apprendre des transformations linéaires ce qui restreindrait trop l'espace des hypothèses [14].

On peut l'exprimer comme une succession de fonctions non linéaires mises en cascade

$$fw(x) = gwn(xn) \circ gwn-1(xn-1) \circ \dots \circ gw0(x) \quad (2.1)$$

où $gw_j(x_j)$ correspond à la couche cachée.

Nous pouvons aussi voir un réseau de neurones comme un extracteur de caractéristiques qui ne sont que les résultats des transformations subies par les données en entrées x .

2.2.2 Applications des réseaux de neurones

- ✓ **Aérospatial** : pilotage automatique, simulation du vol...
- ✓ **Automobile** : système de guidage automatique,...
- ✓ **Défense** : guidage de missile, suivi de cible, reconnaissance du visage, radar, sonar, lidar, traitement du signal, compression de données, suppression du bruit.
- ✓ **Electronique** : prédiction de la séquence d'un code, vision machine, synthétiseur vocal, modèle non linéaire,...
- ✓ **Finance** : Prévission du coût de la vie
- ✓ **Secteur médical** : Analyse EEC et ECG
- ✓ **Télécommunications** : Compression de données...[15]

2.2.3. Réseaux de neurone convolutionnel (CNN)

Les réseaux de neurones étaient juste dotés d'une plus grande capacité que leurs prédécesseurs, mais sans connaissance sur la manière de les entraîner efficacement. Il aura

fallu attendre de meilleurs processeurs mais surtout l'algorithme de rétropropagation proposé par Rumelhart et al. Lecun et al. (1998) ont introduit un premier réseau de neurones convolutif (CNN) dont l'architecture a été baptisée LeNet5, un algorithme permettant de classifieur avec une grande précision des images de chiffres manuscrites. Par la suite, les avancées apportées par Hinton et al ont permis d'entraîner efficacement des réseaux de neurones profonds où plusieurs couches cachées se succèdent en formant une représentation non linéaire dont la complexité augmente au fur et à mesure qu'on avance en profondeur[16].

Les réseaux de neurones convolutionnels (CNN) sont basés sur le perceptron multicouche (MLP), et inspirés du comportement du cortex visuel des vertébrés. Bien qu'efficaces pour le traitement d'images, les MLP ont beaucoup de mal à gérer des images de grande taille, ce qui est dû à la croissance exponentielle du nombre de connexions avec la taille de l'image. Par opposition aux MLP, les CNN ont les traits distinctifs suivants :

1. 'Volumes 3D de neurones' : La couche de neurones n'est plus simplement une surface (perceptron), mais devient un volume avec une profondeur. Si on considère un seul champ récepteur du CNN, les n neurones associés (sur la profondeur) forment l'équivalent de la première couche d'un MLP.

2. 'Connectivité locale' :Grâce au champ récepteur qui limite le nombre d'entrées du neurone, tout en conservant l'architecture MLP, les CNN assurent ainsi que les «filtres» produisent la réponse la plus forte à un motif d'entrée spatialement localisé, ce qui conduit à un représentation parcimonieuse de l'entrée. Une telle représentation occupe moins d'espace en mémoire. De plus, le nombre de paramètres à estimer étant réduit, leur estimation (statistique) est plus robuste pour un volume de données fixé (comparé à un MLP).

3. 'Poids partagés' :

Dans les CNNs, les paramètres de filtrage d'un neurone (pour un champ récepteur donné) sont identiques pour tous les autres neurones d'un même noyau (traitant tous les autres champs récepteurs de l'image). Ce paramétrage (vecteur de poids et biais) est défini dans une « carte de fonction ». Cela signifie que tous les neurones dans une couche de convolution donnée détectent exactement la même caractéristique. En multipliant les champs récepteurs, il devient possible de détecter des éléments indépendamment de leur position dans le champ visuel, ce qui induit une propriété d'invariance par translation [12]. La Figure 2.2 montre la différence entre le CNN et un réseau de neurone traditionnel.

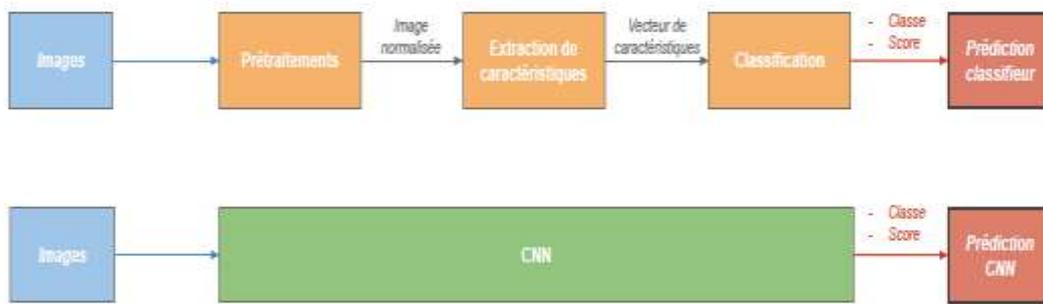


Figure .2.2. Différence entre CNN et Machine Learning Traditionnel pour l'analyse d'images[13].

Un CNN est divisé en plusieurs couches, chacune composée d'autres couches représentant des tâches fondamentales du réseau. La partie réalisant l'extraction des caractéristiques d'une image est composée de couches appelées "couches cachées", et la partie classification est appelée couche de classification ou couche dense. Une couche cachée comporte une ou plusieurs couches de convolutions, associées à une fonction d'activation, et une couche de sous échantillonnage ("pooling"). La couche de classification se divise en deux couches. Une première, la couche de vectorisation combine les caractéristiques locales détectées par les couches précédentes, s'affranchissant alors de leur structure spatiale. Une seconde couche, la couche entièrement connectée, permet une classification des caractéristiques générées par le réseau, qui ont alors été transformées en un vecteur de données. Une dernière fonction d'activation, souvent de type "SoftMax", permet de normaliser les scores associés à chaque classe.

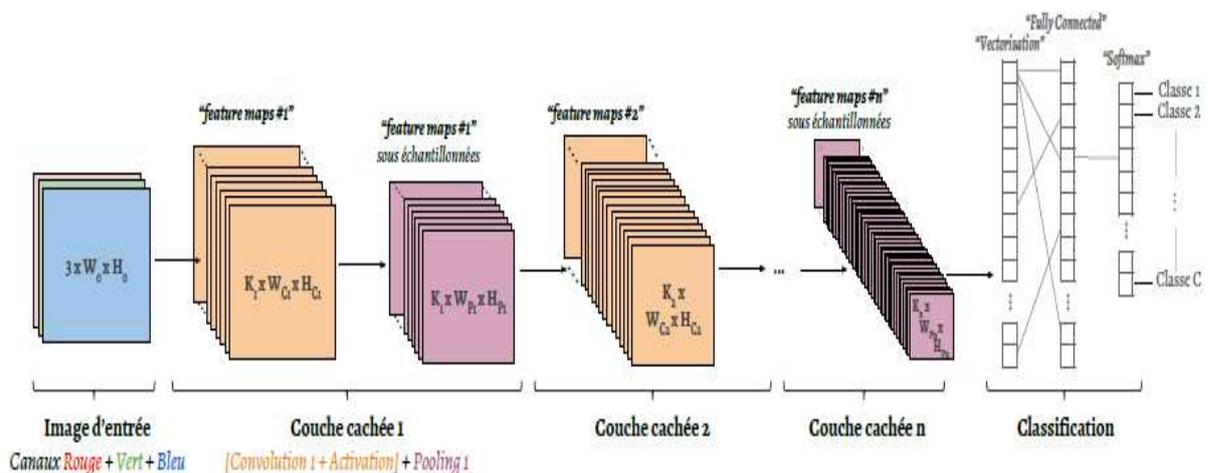


Figure .2.3. Fonctionnement des couches d'un réseau CNN [13].

Chaque couche cachée "i" est constituée de K_i filtres de convolutions (dont les noyaux sont de même taille pour une couche), produisant alors K_i nouvelles images (appelées "feature maps") de dimension $W_{Ci}:H_{Ci}$ inférieure à la dimension de l'image d'entrée $W_{i1}:H_{i1}$. Une fonction d'activation s'applique ensuite à ces "feature maps", qui sont par la suite sous échantillonnées, produisant K_i images sous échantillonnées, de dimensions $W_{Pi}:H_{Pi}$ [13].

2.2.3.1. Explication d'algorithme de réseau de neurone convolutionnel

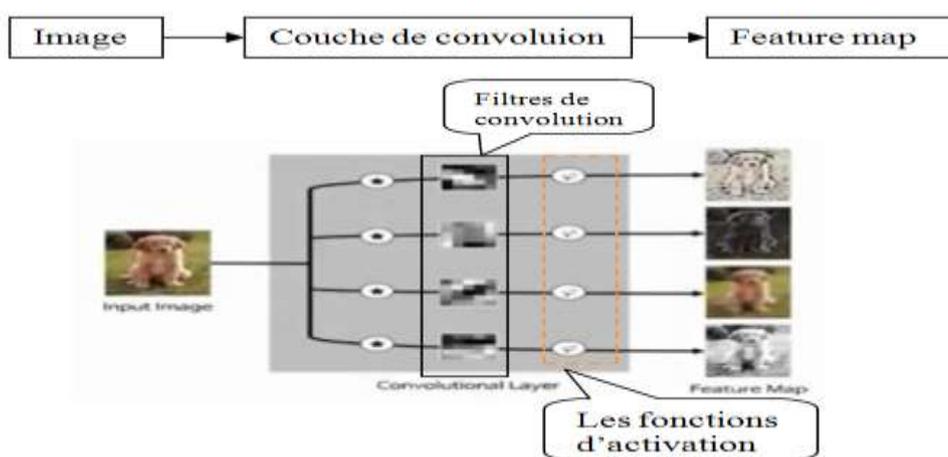


Figure.2.4. Réseau de neurone convolutionnel [17] .

Le premier bloc fait la particularité de ce type de réseaux de neurones ,puisqu'il fonctionne comme un extracteur de features ;Pour cela ,il effectue du template matching en appliquant des opérations de filtrage par convolution.La première couche filtre l'image avec plusieurs noyaux , et renvoie des « feature maps » ,qui sont ensuite normalisées (avec une fonction d'activation) et /ou redimensionnées .

Ce procédé peut être réitéré plusieurs fois : on filtre les features maps obtenues avec de nouveaux noyaux ce qui nous donne de nouvelles features maps à normaliser et redimensionner , et qu'on peut filtrer à nouveau , et ainsi de suite. Finalement , les valeurs des dernières feature maps sont concaténées dans un vecteur .Ce vecteur définit la sortie du premier bloc, et l'entrée du second .

Le second bloc n'est pas caractéristique d'un CNN : il se trouve en fait à la fin de tous les réseaux de neurones utilisés pour la classification .Les valeurs du vecteurs en entrée sont transformées (avec plusieurs combinaisons) linéaire et fonctions d'activation) pour renvoyer un nouveau vecteur en sortie .Ce dernier vecteur contient autant d'éléments qu'il

ya de classes , chaque élément est donc compris entr 0 et 1 , et la somme de tous vaut 1.Ces probabilités sont calculées par la dernière couche de ce bloc (et donc du réseau), qui utilise une fonction logistique (classification binaire) ou une fonction *softmax* (classification multi-classe) comme fonction d'activation[18] .

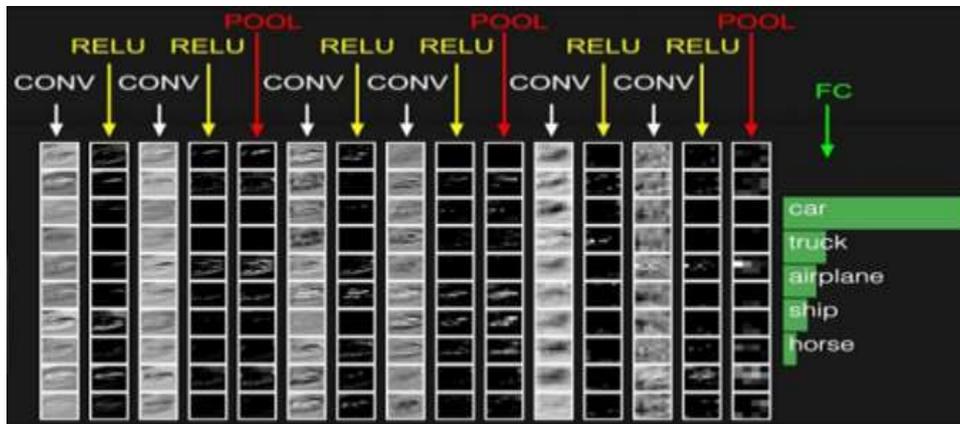


Figure.2.5.Les étapes d'algorithme de réseau de neurone convolutionnel[19].

1) Couche de covolution et d'activation

Un réseau de neurones convolutif est un réseau de neurones qui utilise une opération mathématique qui s'appelle convolution .

Soient f et g deux fonctions définies sur \mathbb{R} , le produit de convolution entre f et g est généralement noté $f * g$ et il est défini par l'équation suivante :

$$S(x) = (f * g)(x) = \int_{-\infty}^{+\infty} f(t)g(x-t)dt \quad (2.2)$$

Dans un réseau de neurones convolutif, le premier argument f est assimilé à l'entrée, le deuxième argument g est assimilé au noyau de convolution et la sortie est assimilée à la carte de caractéristiques. En réalité, les réseaux de neurones convolutifs utilisent une convolution discrète qui est définie par :

$$S(x) = (f * g)(x) = \sum_{a=-\infty}^{+\infty} f(t)g(x-a) \quad (2.3)[20]$$

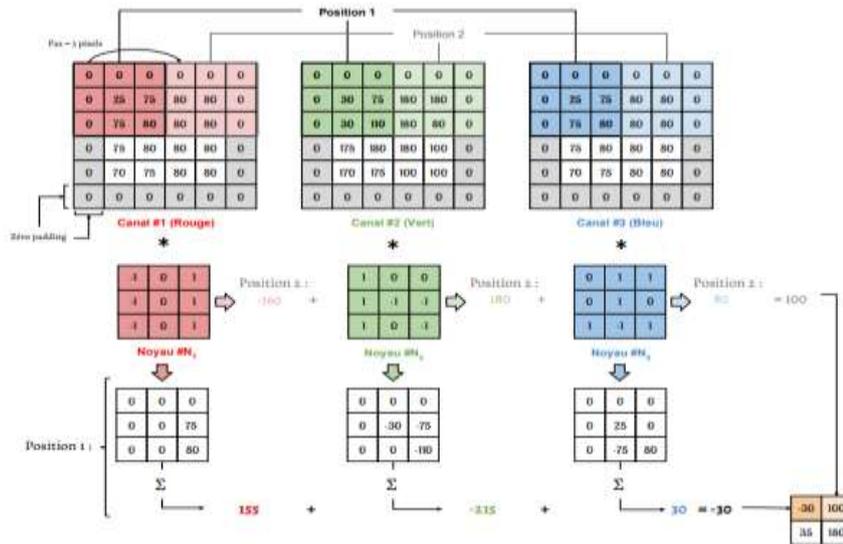


Figure.2.6. L'opération de convolution au niveau de couche de convolution[21].

L'image transférée en entrée du réseau comporte des pixels dont les valeurs sont comprises entre une borne inférieure et une borne supérieure (0 et 255 pour une image 8 bits).

Hors, après une convolution, l'image résultante peut comporter des valeurs au delà de ces bornes. Afin de normaliser ces valeurs, on leur applique une fonction non linéaire d'activation pouvant prendre différentes formes, les principales fonctions d'activations déterminent une nouvelle valeur en fonction de la valeur actuelle du pixel. La plus utilisée est la fonction "ReLU" ("Rectified Linear Unit"). Celle-ci est déterminée par la fonction "max(0, x)", transformant les valeurs négatives en zéros et conservant les autres valeurs. Cette fonction ne modifie pas la résolution spatiale des feature maps et ne comporte aucun paramètre du réseau[21].

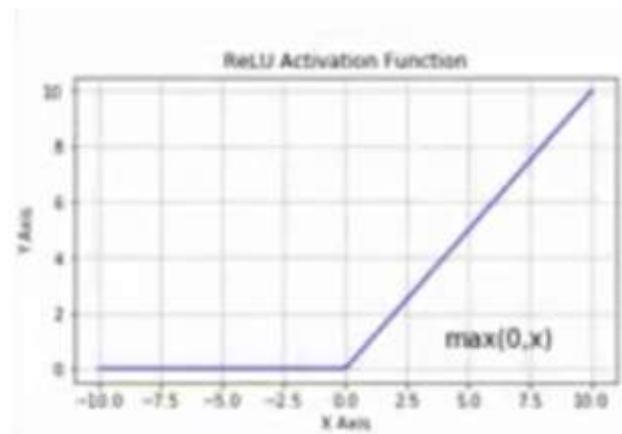


Figure.2.7. La fonction d'activation ReLU[17].

Les couches de convolution possèdent des hyperparamètres, c'est-à-dire des paramètres dont les valeurs sont fixées lors de la conception de l'architecture du réseau. Ils sont au nombre de quatre :

- le nombre de filtres "K".
- la taille D_F des filtres (chaque filtre est de dimensions $D_F \times D_F \times m$ éléments).
- le pas "s" avec lequel on fait glisser la fenêtre correspondant au filtre sur l'image.
- le zero-padding "P".

Considérons une image (ou feature map), dans le réseau en entrée d'une couche de convolution. Cette image est de dimensions $W \times H \times m$, où "W" est sa largeur en pixels, "H" sa hauteur en pixels et "m" le nombre de canaux de l'image ($m = 1$: image en niveaux de gris; $m = 3$: image couleur). C'est à dire les poids et les biais qui sont ajustées lors de l'apprentissage, sont respectivement les éléments des noyaux de convolutions et le biais associé à chaque filtre. On dénombre ainsi " $D_F \cdot D_F \cdot K \cdot m$ " paramètres pour cette couche. Comme l'illustre la figure A.6, le résultat renvoyé par cette couche de convolution est une matrice de dimensions $W_C \times H_C \times D_C$, où :

$$W_C = \frac{W - D_F + 2 \cdot P}{s} + 1 \quad | \quad H_C = \frac{H - D_F + 2 \cdot P}{s} + 1 \quad | \quad D_C = m \quad (2.4)$$

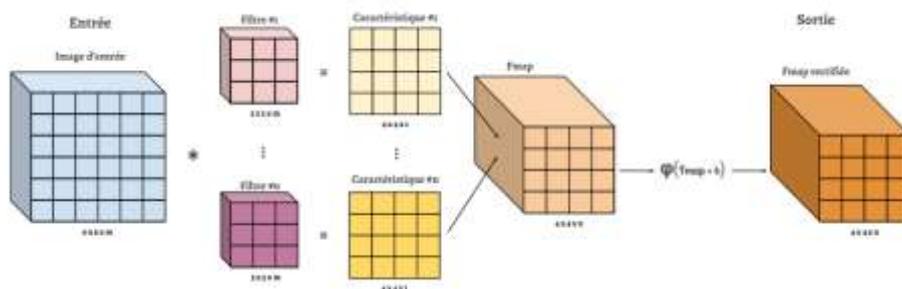


Figure.2.8. Illustration de l'ensemble convolution et activation [21].

2) Couche pooling

La couche d'échantillonnage est chargée de réduire la taille spatiale des cartes de caractéristiques, mais elle conserve les informations les plus importantes. Il existe différents types d'échantillonnage dont l'échantillonnage maximum -ou Max Pooling-, l'échantillonnage moyen -ou Average Pooling-, etc. L'échantillonnage consiste à appliquer un noyau de taille $n \times n$ sur la carte d'activation en le faisant glisser avec un pas préalablement défini (le pas est généralement égal à la taille du noyau n pour éviter le phénomène de chevauchement).

Le Max Pooling renvoie la valeur maximale de la partie de l'image couverte par le noyau. Au lieu de prendre le maximum, nous pourrions prendre la moyenne de tous les éléments couverts par le noyau, cela est assuré par le Average Pooling. Le Max Pooling permet de supprimer le bruit. D'autre part, le Average Pooling effectue simplement une réduction de la dimensionnalité en tant que mécanisme de suppression de bruit.

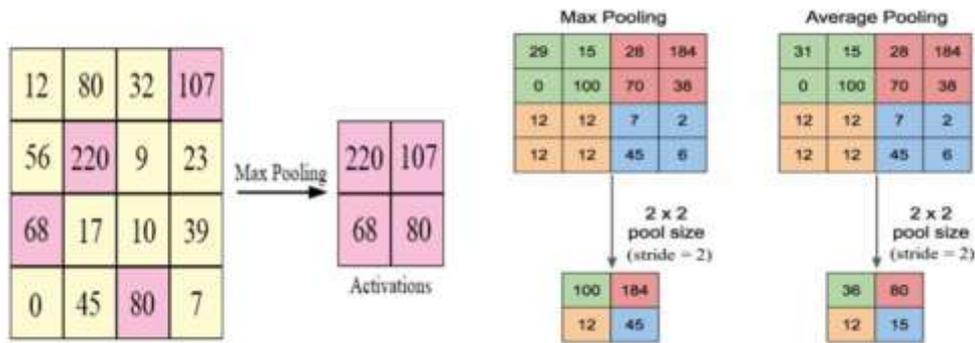


Figure.2.9. Exemple d'une opération de pooling de taille 2x2[20].

Plus généralement, la couche de pooling :

- accepte un tenseur de taille $W_1 \times H_1 \times D_1$
- nécessite deux hyperparamètres : la taille F et le pas s avec $F < W_1$ et $F < H_1$
- produit un tenseur de taille $W_2 \times H_2 \times D_2$ où :
- $W_2 = \frac{(W_1 - F)}{s} + 1$ (2.5)
- $H_2 = \frac{(H_1 - F)}{s} + 1$ (2.6)
- $D_2 = D_1$ [20]

3) Couche de vectorisation (Flattening)

Après l'enchaînement d'un certain nombre de couches de convolutions/pooling, l'image d'entrée du réseau se retrouve être une feature map dont la largeur et la hauteur sont très petites par rapport à cette image d'entrée, et la profondeur (nombre de canaux) très grande. La classification s'effectue par une couche entièrement connectée, que nous verrons par la suite, qui ne prend pas en compte de structure spatiale. Il n'est donc plus nécessaire de conserver les informations sous la forme d'une feature map. Ainsi, une étape "d'aplatissement" ou de vectorisation est nécessaire afin de combiner les caractéristiques locales détectées par les couches précédentes. Les éléments de chaque canaux de la dernière feature map sont empilés pour créer un vecteur de données. Cette feature map en sortie de la couche "n" possède donc trois dimensions, $W_n \times H_n \times D_n$, et la phase de vectorisation la transforme en un vecteur de dimensions $W_n \cdot H_n \cdot D_n$ [21].

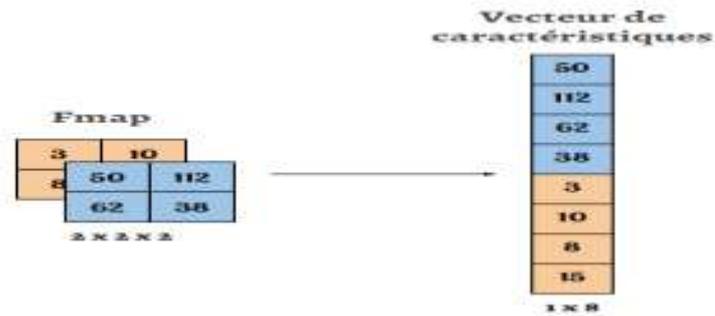


Figure.2.10. Illustration de l'étape de "flattening"[21].

4) **Couche entièrement connectée (classification) :**

Relient chaque neurone entre eux. Cet ensemble de couches entièrement connectées forment un réseau de neurones traditionnel. Pour effectuer une classification des caractéristiques générées par le réseau, qui ont alors été transformées en un vecteur de données, la dernière des couches utilise une fonction d'activation de type "Softmax", ou fonction de normalisation exponentielle. La fonction d'activation Softmax permet de normaliser les scores associés aux classes pour obtenir des valeurs comprises entre 0 et 1. La somme des résultats associés à chaque classe est égale à 1 et représente donc une probabilité associée à chacune de ces classes (distribution des probabilité).

$$f_j(z) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, \forall j \in [1;K] \text{ avec } \sum_{j=1}^K f_j(z) = 1 \quad (2.7)$$

où "z" est un vecteur de "K" éléments en sortie du réseau comportant les scores associés aux "K" classes, et j correspond à la jème classe du vecteur "z"[21].

2.2.3.2. **Application d'algorithme CNN sur une image**

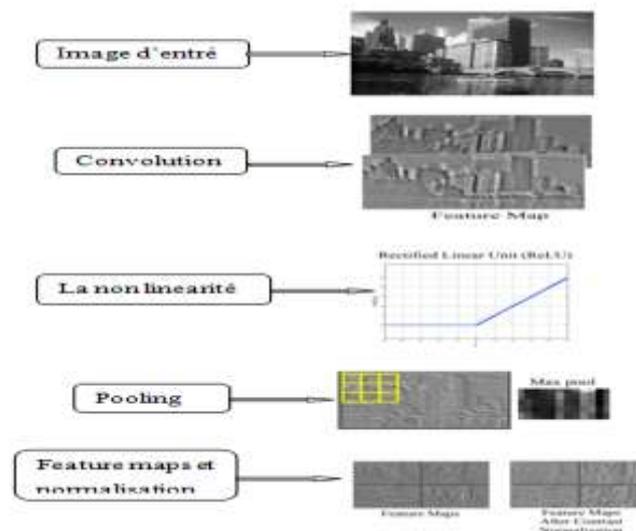


Figure.2.11. Application d'un algorithme CNN[22].

2.2.3.3. Évaluation des méthodes

Metriques d'évaluation

Les sections précédentes ont montré qu'il existe un grand nombre de solutions aux problèmes de classification d'images dans le domaine de la biométrie. Les méthodes présentées peuvent être utilisées pour des problèmes de classification à deux ou plusieurs classes, et le comportement des classifieurs dépend du nombre d'échantillons par classe ainsi que de leur composition. Par conséquent, la sélection de la méthode la plus appropriée est dépendante des contraintes liées à l'application ciblée. Une solution consiste à effectuer une première sélection de méthodes, à les tester puis à réaliser une série d'évaluations. Les techniques d'analyse des données utilisent habituellement comme point de départ une représentation sous forme de tableau, que l'on appelle matrice de confusion ou tableau de contingence, mettant en relation le nombre de prédictions " $X_{i,j}$ " (X_{classe} , prediction) des échantillons de la classe " i " attribués à une classe " j " (parmi C classes). Le nombre d'échantillons formant la classe " i " est noté " K_i ", et le nombre total de prédictions attribuées à cette classe est nommé " M_i ". La somme des " K_i " ainsi que la somme des " M_i " correspondant au nombre total d'échantillons (Σ)

		prédiction			Total/classes
		<i>classe 1</i>	<i>classe i</i>	<i>classe c</i>	
Classe réelle	<i>classe 1</i>	$X_{1,1}$	$X_{1,i}$	$X_{1,c}$	K_1
	<i>classe i</i>	$X_{i,1}$	$X_{i,i}$	$X_{i,c}$	K_i
	<i>classe c</i>	$X_{c,1}$	$X_{c,i}$	$X_{c,c}$	K_c
prédictions		M_1	M_i	M_c	Σ

Table 2.1. Matrice de confusion des prédictions d'un classifieur à C classes.

En considérant le problème précédent, pour chacune des classes " i ", comme étant binaire (Classe " i " : positif; Toutes les autres classes " j , i " : négatif), ou directement dans le cas d'un problème à deux classes, les prédictions sont résumées sous la forme de quatre informations principales :

- **Vrais Positifs - VP ("True Positive" - TP)** : Échantillons de la classe positive (" i ") correctement classés ($X_{i,i}$).

- **Faux Négatifs - FN ("False Negative" - FN)** : Échantillons de la classe positive ("i") incorrectement classés ($X_{i,j}, \forall j, i$).
- **Vrais Négatifs - VN ("True Negative" - TN)** : Échantillons des classes négatives ("j") correctement classés ($X_{j,t}, \forall (j, t) \in [1, C], i$).
- **Faux Positifs - FP ("False Positive" - FP)** : Échantillons des classes négatives ("j") incorrectement classés ($X_{j,i}, \forall j, i$).

Pour un problème à N classes, considéré comme binaire pour le test de chacune des classes, il y a autant de matrices de confusion qu'il y a de classes, chacune représentant les performances de la classification vis à vis de la classe "i". La matrice de confusion pour un problème à deux classes établit ainsi le lien entre le nombre d'échantillons total (P) de la classe positive, le nombre d'échantillons total (N) de la classe négative, les quatre informations précédentes et par conséquent le nombre total d'échantillons classés positivement (Ppos) et négativement (Pneg). Cependant, du fait que la quantité d'échantillons par classe peut varier entre les différentes classes et des différentes problématiques, son exploitation n'est pas toujours facile.

		prédiction		Total/classes
		Classe positive	Classe négative	
Classe réelle	Classe positive	V_p	F_N	P
	Classe négative	F_p	V_N	N
prédictions		P_{Pos}	P_{neg}	Σ

Tableau.2.2. La matrice de confusion.

Des critères de performances dérivent de cette matrice de confusion et permettent d'évaluer rapidement les performances de classification. Ces nouvelles métriques représentent des indications normalisées de ces performances sous forme d'un pourcentage. Il est ainsi possible d'analyser et de comparer les performances de différents classifieurs. Ces mesures sont les suivantes :

- **Sensibilité ou Rappel (Sensitivity ou Recall)** : Proportion des solutions pertinentes correctement identifiées (taux de vrais positifs). Mesure la capacité du système à donner toutes les solutions pertinentes.

- Cas général (problème à C classes) :

$$Sensibilite_i = \frac{X_{i,i}}{K_i} \tag{2.8}$$

$$Sensibilite_{Systeme} = \frac{\sum_{c=1}^C sensibilite_i}{c} \Rightarrow \frac{Echantillon\ correctement\ attribués\ à\ la\ classe\ i}{echantillons\ de\ la\ classe\ i} \quad (2.9)$$

- Pour un problème deuxième classe

$$Sensibilité = \frac{V_P}{V_P + F_N} = \frac{V_P}{P} \quad (2.10)$$

- **Spécificité (Specificity)** : Proportion de solutions négatives correctement identifiées (taux de vrais négatifs). Mesure la capacité du système à reconnaître toutes les situations négatives. C'est une mesure complémentaire de la sensibilité.

- Cas général (problème à C classes) :

$$Specifite_i = \frac{\sum_{j=1}^C \sum_{t=1}^C X_{j,t}}{\sum_{j=1}^C K_j}, \forall (j,t) \in [1,C] \neq i \quad (2.11)$$

$$Specifite_{Systeme} = \frac{\sum_{i=1}^C specifite_i}{c} \Rightarrow \frac{Echantillon\ correctement\ attribués\ à\ la\ classe\ i \neq j}{echantillons\ n'appartenant\ pas\ à\ la\ classe\ i} \quad (2.12)$$

- Pour un problème deuxième classe

$$Spécifite = \frac{V_N}{V_N + F_P} = \frac{V_N}{N} \quad (2.13)$$

- **Précision (Precision)** : Proportion de solutions correctes parmi les prédictions positives. Mesure la capacité du système à refuser les solutions non-pertinentes.

- Cas général (problème à N classes) :

$$precision_i = \frac{X_{i,i}}{M_i} \quad (2.14)$$

$$precision_{Systeme} = \frac{\sum_{i=1}^C precision_i}{c} \Rightarrow \frac{Echantillons\ correctement\ attribués\ à\ la\ classe\ i}{echantillons\ attribués\ à\ la\ classe\ i} \quad (2.15)$$

- Pour un problème à deuxième classe

$$Sensibilité = \frac{V_P}{V_P + F_P} = \frac{V_P}{P_{pos}} \quad (2.16)$$

- **Robustesse, exactitude ou justesse (Accuracy)** : Proportion des solutions correctes (positives et négatives) parmi toutes les prédictions. Mesure la capacité du système complet à donner toutes les solutions correctes.

$$Justesse = \frac{V_P + V_N}{V_P + V_N + F_P + F_N} = \frac{P}{\Sigma} \Rightarrow \frac{Echantillons\ correctement\ attribués}{totalité\ des\ echantillons} \quad (2.17)$$

- **Fβ-mesure (Fβ-measure) or F-Score** : Combine la précision et le rappel de par leur moyenne harmonique. Fourni une mesure favorisant soit le rappel soit la précision dans le cas d'une classification à partir de données non équilibrées.

$$F_{\beta} = \frac{(1+\beta^2)(precision.Rappel)}{\beta^2.precision.Rappel} \quad (2.18)[21]$$

2.3. Transformée en Ondelettes

Cette partie du chapitre est consacrée à l'outil mathématique : la transformée en Ondelettes. L'analyse par ondelettes a été introduite au début des années 1960, dans un contexte d'analyse du signal et d'exploration pétrolière. Il s'agissait à l'époque de donner une représentation des signaux, permettant de faire apparaître simultanément des informations temporelles (localisation dans le temps, durée) et fréquentielles, facilitant par là l'identification des caractéristiques physiques de la source du signal. Les ondelettes n'ont depuis, cessé de se développer et de trouver de nouveaux champs d'application [12]

La transformée en ondelettes est l'un des outils les plus puissants utilisés en traitement du signal et de l'image. Car, grâce à la décomposition multi-échelle qu'elle induit, elle permet, notamment, d'analyser les signaux à différentes résolutions. Projetant les signaux dans le plan temps-fréquence, elle permet également d'étudier l'évolution de leur spectre de fréquences au cours du temps. De surcroît réversible, elle autorise les traitements dans l'espace transformé, c'est-à-dire à une résolution différente ou dans le plan temps fréquence[23].

L'idée de l'analyse ondelettes est de décomposer un signal sur une base de fonction d'un espace fonctionnel ayant des propriétés bien déterminées. Il s'agit d'analyser un signal en cherchant une représentation plus compacte localisée simultanément en temps et en fréquence au principe d'Heisenberg près. Les fonctions de bases de l'espace fonctionnel utilisées sont appelées ondelettes[24]. La Figure 2.12 illustre la décomposition multirésolution en transformée en ondelettes d'une image.

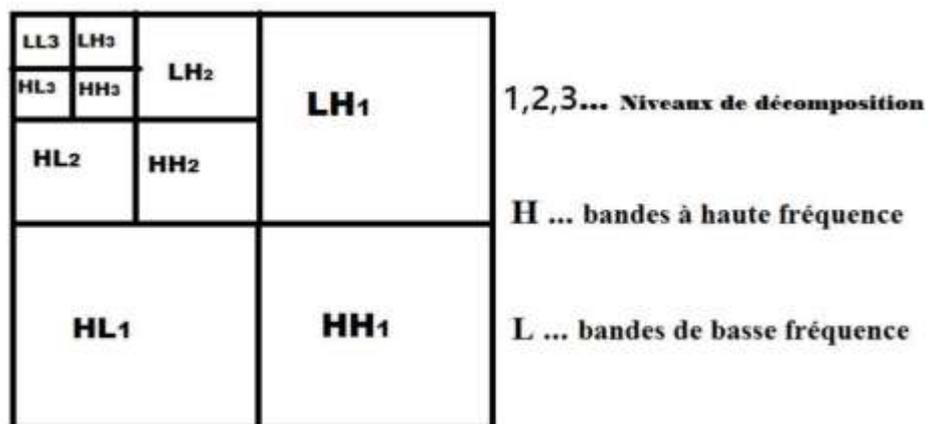


Figure.2.12. Niveaux de décomposition en ondelettes [1].

Dans notre travail, nous exploitons la transformée en ondelettes discrète 2D dans la fusion de deux images.

2.4 Fusion D'images Dans Le Domaine De Transformée En Ondelettes

La Figure 2.13 illustre le principe de fusion de deux images dans le domaine de transformée en ondelettes. Il faut noter que la fusion se calcule par les coefficients de transformées en ondelettes des deux images.

Les transformées qui ont été utilisées dans la fusion d'images incluent la transformée pyramidale, la transformée en cosinus discrète (Discrete Cosine Transform DCT), la transformée de Fourier discrète (DFT), les transformées en ondelette telles que la DWT.

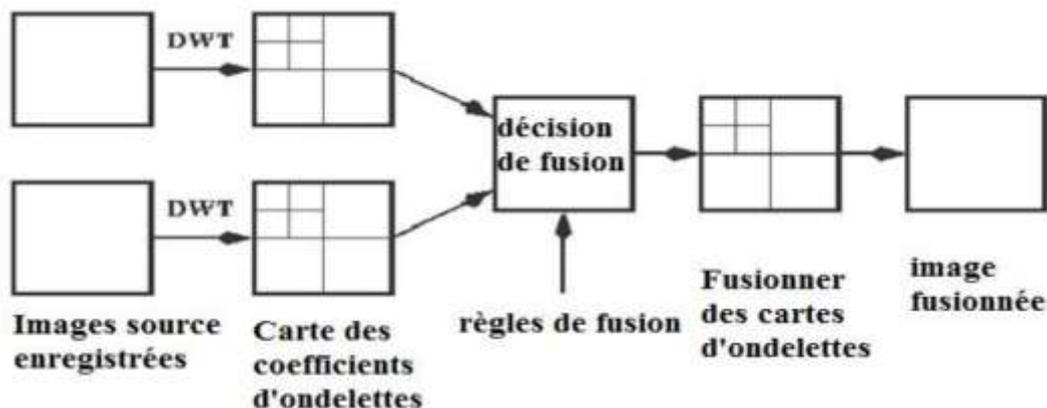


Figure.2.13 Fusion de deux images à l'aide de transformées en ondelettes[1].

2.4.1.Règles de Fusion dans le Domaine d'Ondelettes (Règles de Fusion (Min, Max, Moy))

Certains algorithmes utilisent des règles de sélection pixel par pixel, comme le maximum absolu, la moyenne et le minimum des coefficients d'ondelettes des images sources à l'instar des règles de fusion proposées dans le domaine spatial. Les règles de fusion qui sont basées sur la sélection du minimum et le calcul de la moyenne entraînent un faible contraste et sont moins utilisables que la règle de sélection du maximum.

Règle de Fusion d'Images Basée sur le Contraste

La fusion d'images basée sur le contraste est une méthode de fusion niveau pixel basée sur la perception visuelle humaine. Cette technique utilise une mesure appelée contraste de la

direction de l'ondelette. Elle associe les caractéristiques de la décomposition multirésolution et la sensibilité visuelle humaine au contraste local.

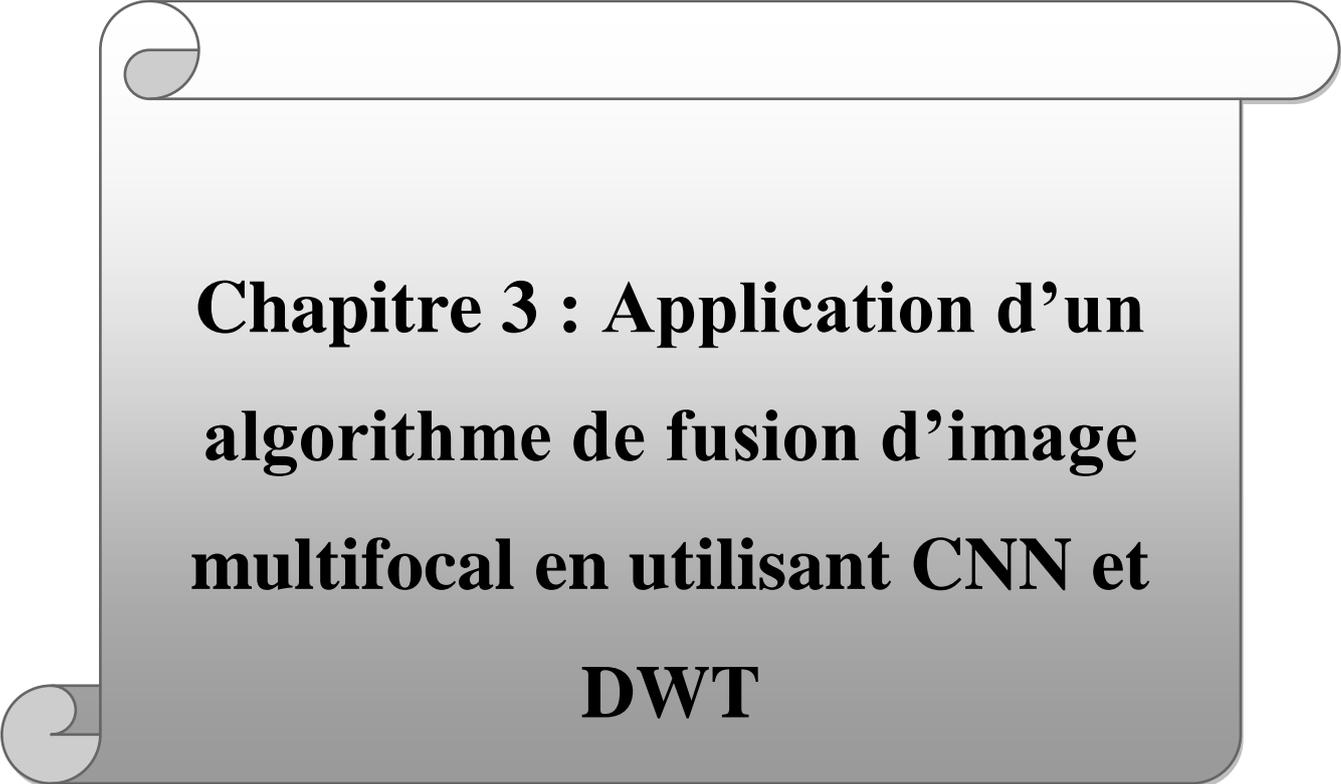
Fusion d'Images Basée sur la Variance des Coefficients

Des techniques de fusion d'images niveau pixel. Dans cette méthode, les coefficients de détails de l'image fusionnée sont obtenus en comparant les caractéristiques de variance des images sources à un emplacement spécifique.

2.5 Conclusion

Dans ce chapitre, nous avons présenté les réseaux de neurones convolutionnels. Ces réseaux sont capables d'extraire des caractéristiques d'images présentées en **entrée** et de classifier ces caractéristiques, nous avons discuté des notions fondamentales des réseaux de neurones en générale et des réseaux de neurones convolutionnels en particulier. Dans la deuxième section nous aborderons les notions fondamentales d'ondelettes et leur principe de fonctionnement, nous avons étudiés la transformée en ondelette discrète comme une méthode utilisée dans notre étude.

Dans nos expériences de simulation dans le chapitre suivant, nous combinons les CNN avec la transformée en ondelettes pour améliorer la qualité des images fusionnées.



**Chapitre 3 : Application d'un
algorithme de fusion d'image
multifocal en utilisant CNN et
DWT**

3.1. Introduction

L'obtention d'une image plus performante et plus précise nécessite une amélioration de l'information de cette image, cette amélioration est effectuée par la fusion de deux images qu'elles soient identiques ou différentes.

Nous proposons d'utiliser la méthode DWT avec le réseau de neurones convolutif CNN pour obtenir une image fusionnée claire .

Dans ce chapitre, nous allons implémenté l'algorithme de fusion d'images multifocales dans le domaine de transformée en ondelettes discrète 2D et en se basant sur les CNN.

3.2 Résultats et Discussions

3.2.1. Logiciel MATLAB

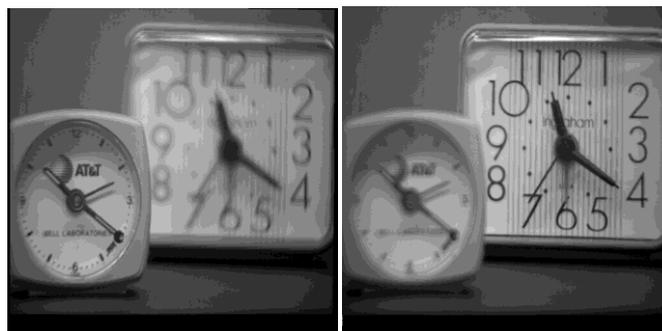
Nous allons présenter la mise en œuvre de notre application en utilisant le langage **Matlab version 7.9.0.529(R 2009 b)** sur un PC de RAM 218 GO.

3.2.2. Nature De Données

Les images test que nous avons utilisé dans notre étude de simulation, sont des images niveaux de gris multifocus, tirées de la bibliothèque toolbox Matlab La taille de ces images est entre 256x 256 et 512x512.

Les images utilisées dans cette partie sont d'un ensemble multi-focus enregistrées de la même scène avec chacune un focus de la caméra différent (clock A et clock B, image x-ray medA et image IRM medB,med A et med B).

La fusion des images multi-focus est illustrée dans la figure 3.1.



(a)

(b)

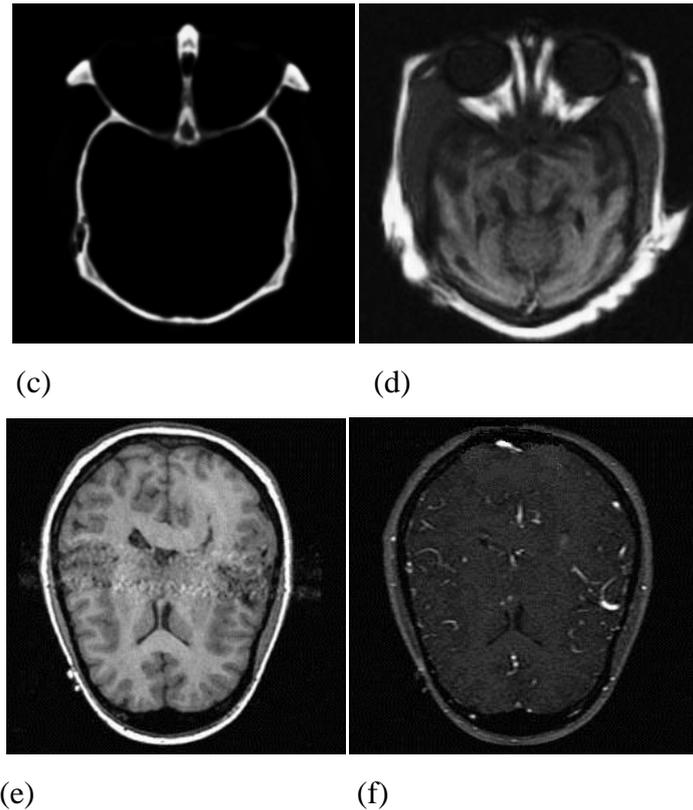


Figure.3.1.Ensemble des images monofocus originales (a) images multi-focus *clockA.tif* (b) image multi-focus *clockB.tif* (c) image x-ray *medA.jpg* (d) image IRM *medB.jpg* (e)med A.JPEG (f) med B.JPEG.

Dès que les images sont acquises aux différentes positions Z, elles sont combinées en une seule image composite, parfaitement nette et avec une profondeur de champ considérablement étendue.

En cas où l'image qui contient deux éléments, lorsque l'on considère l'accent sur quelque chose de l'image, les autres éléments de l'image seront un peu flous. Ces images sont appelées images multi-focus où les éléments des figures ont des focus différents. La fusion des images permet de faciliter l'unification des focus des éléments de l'image fusionnée, l'image dans ce cas sera très claire. L'objectif de la fusion est d'avoir la clarté des deux objets dans l'image fusionnée finale

3.2.3. Fusion d'Images Multifocale Dans Le Domaine Spaciale

L'obtention d'une image plus performante et plus précise nécessite une amélioration de l'information de cette image, cette amélioration est effectuée par la fusion de deux images qu'elles soient identiques ou différentes.

Dans cette partie de travail, nous allons appliqué algorithme de fusion dans le domaine spatial.

Deux règles de fusion seront adoptées: (a) la règle de fusion moyenne (mean) et (b) la règle de fusion max. Dans cette partie, nous utilisons des images multi-focus (clockA, clockB). Les algorithmes seront évalués à travers les calculs de plusieurs critères de performance. La Figure 3.2 illustre les étapes de l'algorithme de fusion.

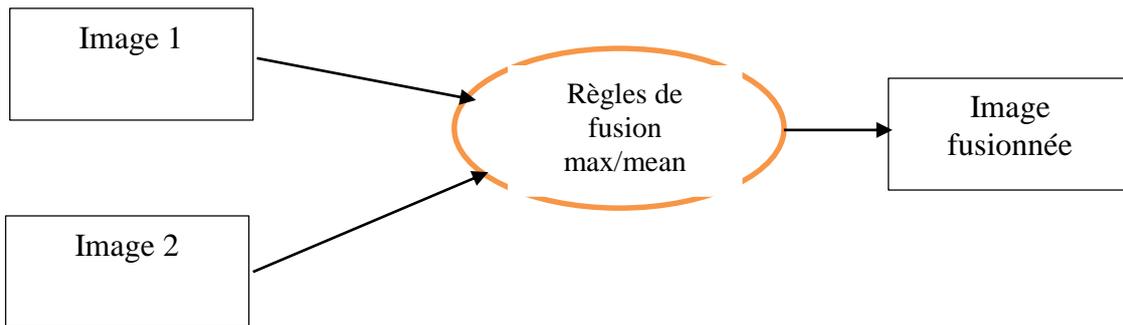


Figure 3.2. les étapes de l'algorithme de fusion.

3.2.3.1. Calcul de Critère D'Evaluation

La figure suivante représente la fusion d'image dans le domaine spatial avec les règles de fusion (max, mean)

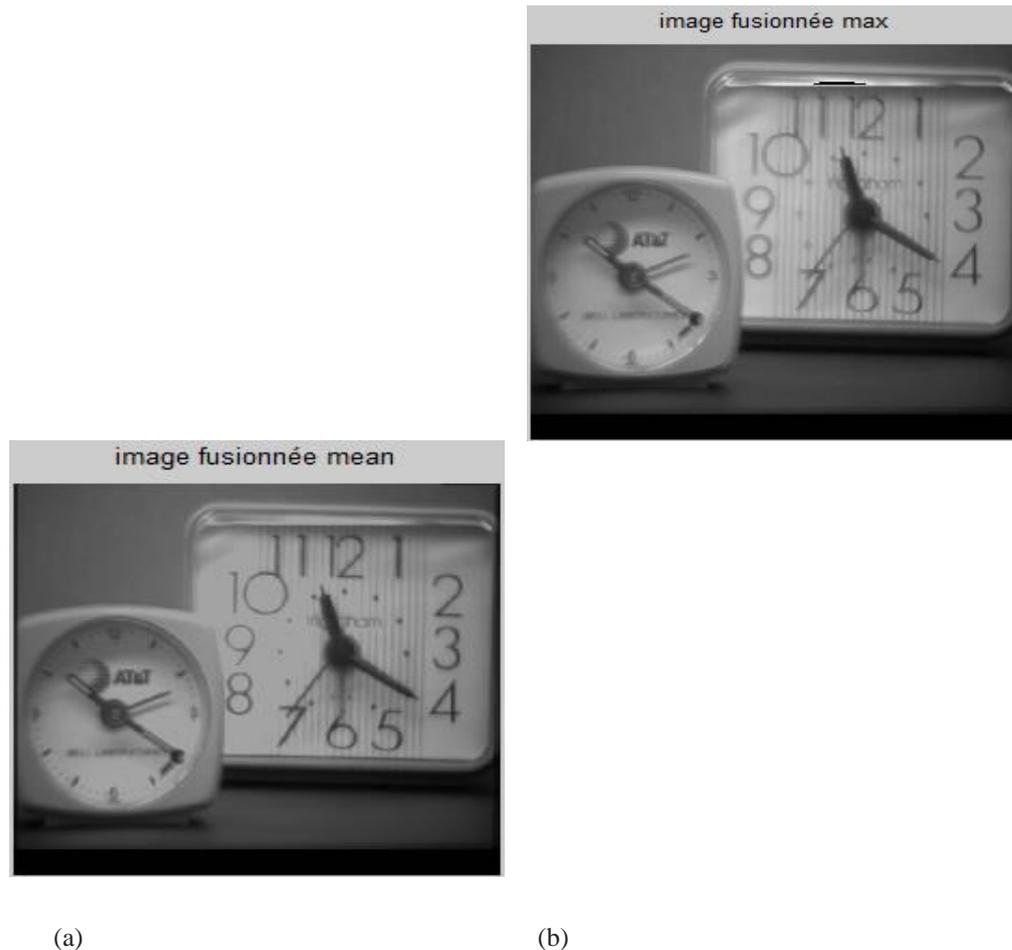


Figure 3.3.Fusion d'images multi-focus.(a) image fusionnée avec la règle de fusion mean, (b)image fusionnée avec la règle de fusion max .

Les paramètres de La fusion de deux images multi-focus (clockA.tif, clockB.tif) dans le domaine spatial sont illustrés au tableau 3.1.

	Paramètre 1: Entropie	Paramètre 2 SNR	Paramètre 3 MSE	Paramètre 4 Sigma
Règle de fusion mean	211	3355	4098	028
Règle de fusion max	011	0323	5620	030

Tableau 3.1.Evaluation des performances des méthodes de fusion dans le domaine spatial en fonction des règles de fusion, image "multi focus.

D'après la figure 3.2 et le tableau 3.1 nous remarquons que La fusion d'image sur la règle max est plus clair par rapport à la fusion avec la règle mean.

3.2.4. Résultats Des Algorithmes Conventionnels De Fusion d'Images à Base De DWT

3.2.4.1. L'organigramme

L'algorithme de fusion de deux images en utilisant la transformée en ondelette discrète est illustré dans la figure 3.3.

Les étapes de l'algorithme sont :

- Décomposer chacune des images par DWT 2D, l'ondelette d'analyse est sym8, le niveau de résolution est 1.
- Fusionner les coefficients de transformée en ondelettes des deux images. Nous utilisons la même règle de fusion pour les coefficients détail et approximation. Les règles de fusion utilisées sont : max et mean.
- Calculer la transformée d'ondelettes inverse à partir des coefficients fusionnés pour obtenir l'image fusionnée multifocus ou multimodale.

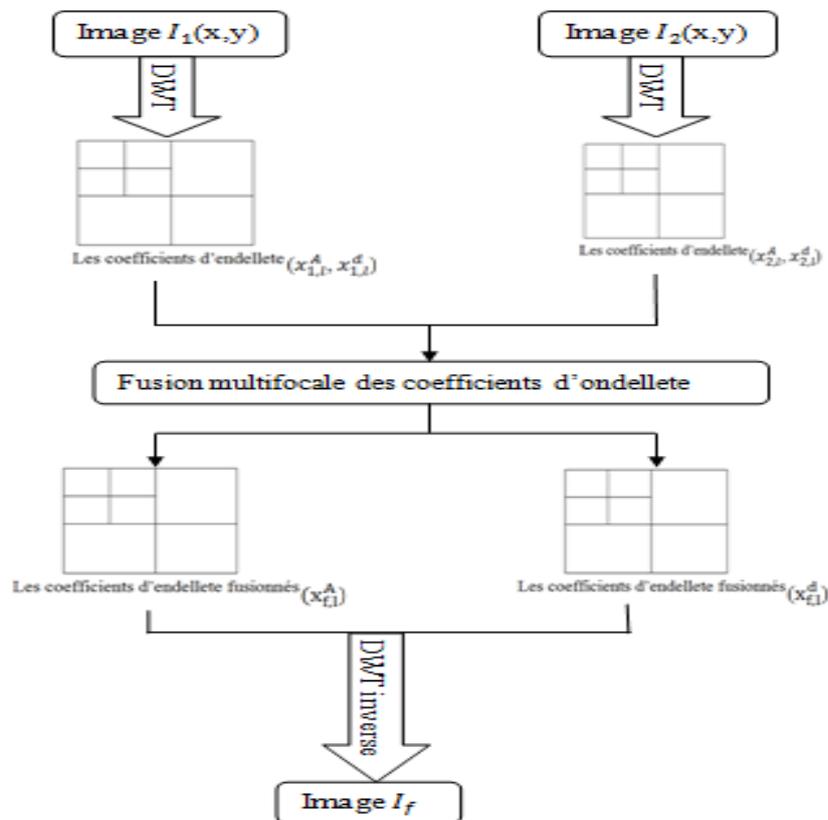


Figure.3.4. Processus générale de fusion d'images par la transformée en ondelettes.

3.2.4.2. Résultats et Discussions

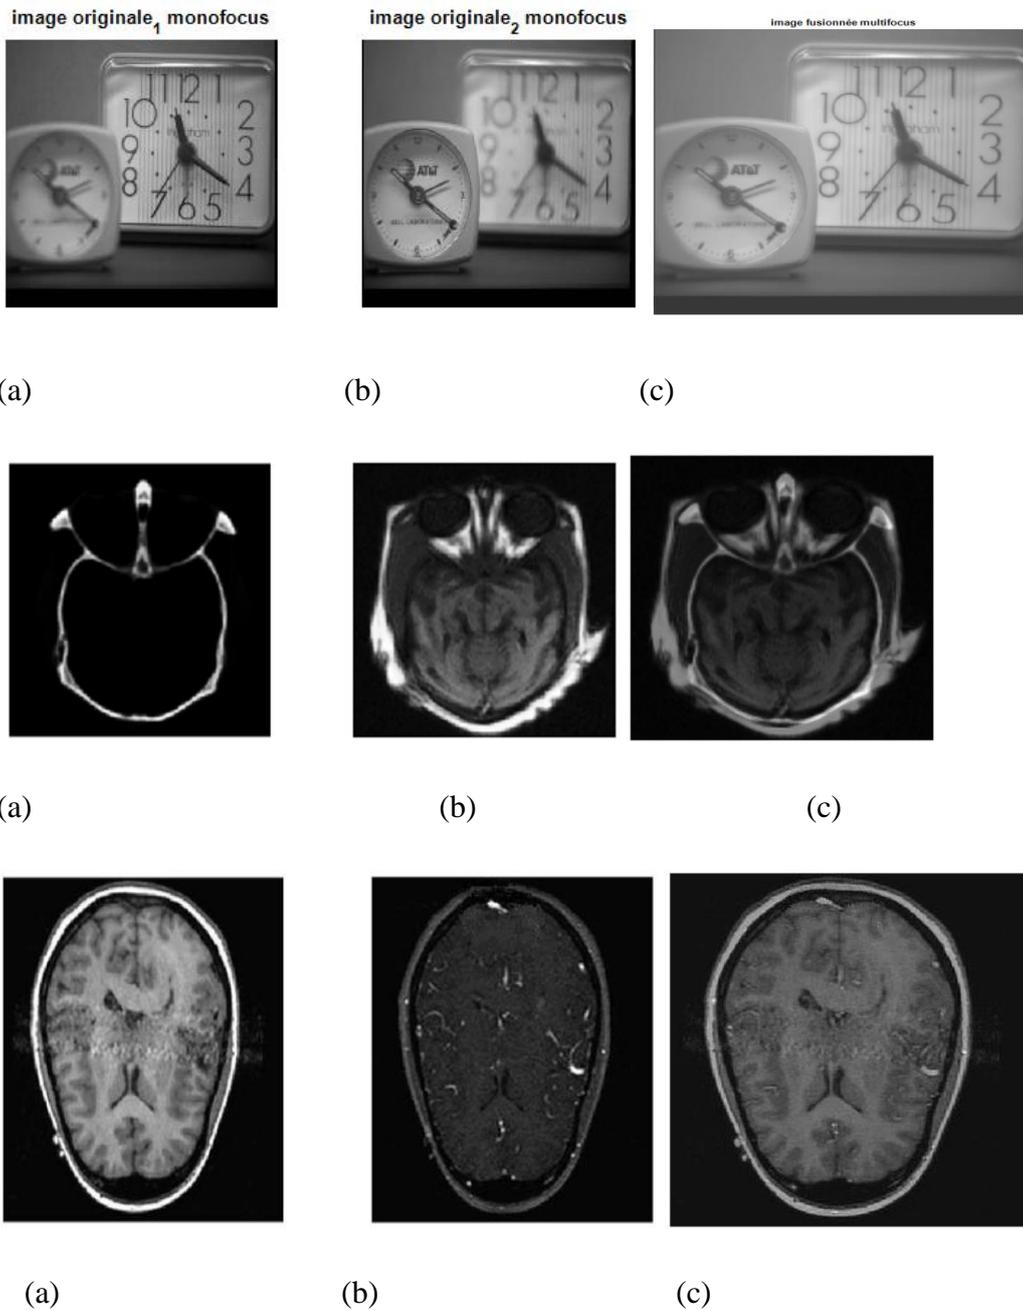


Figure.3.5.Résultats visuels de fusion pour la fusion multifocale par la transformée en Ondelette discrète,(a) et (b) les images test monofocus,(c) l'image fusionnée .

3.2.4.3.Evaluation de performance

Les critères d'évaluations que nous avons calculé sont :

- 1-Standard deviation (std) c'est-à-dire l'écart type
- 2-l'entropie
- 3-Le facteur de fusion (information mutuelle = mutual information)
- 4-fusion structural similarity (ssim)

5-visual information fidelity

➤ **Résultats de simulation**

	Paramètre 1: Entropy	Paramètre 2: standar deviation(std)	Paramètre 3: visual information fidelity (vif):	Paramètre4: Fusion Factor (mutual information)(FF)	Paramètre 5: Fusion structural similarity based image quality measurement(fssim)
La règle de fusion :max	0.1012966	39.7306632	0.7034942	6.7336383	
La règle de fusion :min					0.9327992

Tableau 3.2.Evaluation des performances de la méthode de fusion DWT en fonction de l'ondelette d'analyse, image "multifocus .

Nous remarquons, que l'image fusionnée est bien claire. Les valeurs des critères d'évaluation entre les familles d'ondelette sont très proches. Ceci est du fait que toutes ces ondelettes constituent des bases orthogonales.

3.2.5.1. L'organigramme

L'algorithme de fusion de deux images en utilisant le réseau de neurone convolutionnel est ullistré dans la figure 3.4.

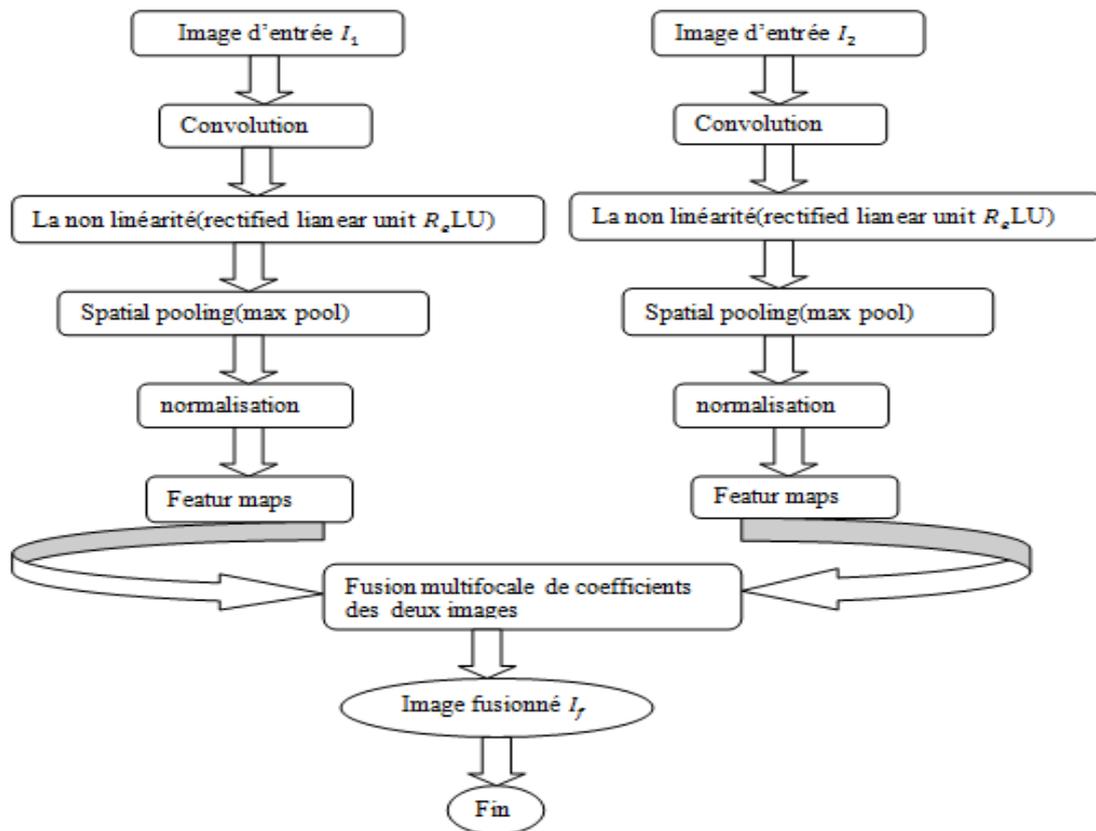


Figure.3.6.Processus générale de fusion d'images par la méthode de réseau de neurone convolutionnel.

Figure.3.7.Résultats visuels de fusion pour la fusion multifocale par la méthode de neurone convolutionnel,(a) et (b) les images test monofocus,(c) l'image fusionnée .

3.2.6.Implémentation des Algorithmes de Fusion d'Images à Base de CNN dans le domaine de DWT

3.2.6.1.L'organigramme

Nous proposons d'utiliser la méthode transformée en ondelette discrète et le réseau neuronal à convolution pour obtenir une image claire[1].

La première image sera décomposée en 4 petites régions, la même opération est appliquée pour la deuxième image mais en utilisant la méthode CNN, puis on applique la fusion

multifocale entre les coefficients obtenus par chaque image. La règle de fusion est basée sur le maximum des coefficients

La Figure 3.6 représente les principales étapes de l'algorithme de fusion.

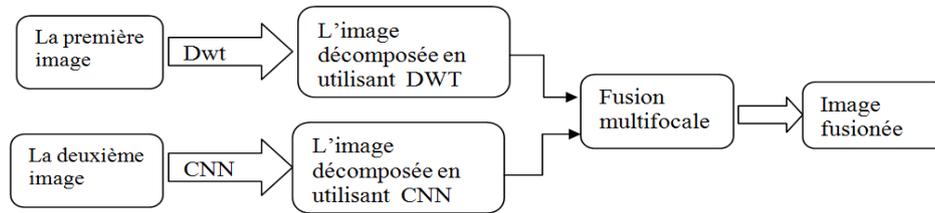


Figure.3.8. Processus générale de fusion d'images par la méthode de réseau de neurone convolutionnel et la transformée en ondelette discrète .

3.3 Comparaison De Résultats Obtenus

Notons que la comparaison se fait sur l'ensemble des paramètres, il ne faut pas prendre chaque paramètre séparément. Nous ne pouvons jamais trouver une méthode qui est bien meilleure en terme de tous les paramètres. Notons également que l'objectif de l'application de la Transformée d'Ondelettes pour la fusion, est de tirer profit des avantages de la Transformée en ondelettes (TO). En fait à travers la TO, l'image sera représentée par quelques coefficients non nuls, ce qui va faciliter et organiser l'opération de fusion. Au lieu de prendre toute l'image, comme dans le domaine spatial, la fusion sera appliquée uniquement sur les quelques coefficients significatifs de la TO.

Alors les résultats obtenus confirme que la fusion multifocale en utilisant DWT et CNN dans le domaine de transformée permet d'obtenir des images claires de bonnes qualité et de meilleurs résolution par rapport à l'unimodalité.

3.4 Conclusion

Dans ce chapitre, nous présentons les résultats obtenus au cours de ce travail. Nous avons décrit des méthodes d'intégration dans deux domaines différents. Ceux-ci incluent le domaine spatial et le domaine de la transformée en ondelettes discrète (DWT). Nous avons constaté que les règles de fusion max et moyenne donnaient des résultats très similaires, cependant, la règle de fusion moyenne est légèrement supérieure à la règle de fusion max.

L'objectif de l'algorithme appliqué est de résoudre le problème suivant : étant donné deux images d'appareil photo, il est nécessaire de combiner les images en une seule image qui contient tous les objets mis au point sans produire de détails qui n'y sont pas. Des photos. Bien que l'algorithme de fusion puisse être directement étendu pour gérer plus de deux images sources

Conclusion Générale

L'objectif principal de ce travail était d'implémenter des algorithmes de fusion appliqués aux images multifocales. L'intérêt suscité est l'amélioration quantitative et qualitative des images fusionnées et de construire des algorithmes aide au diagnostic.

Parmi les nombreuses méthodes de fusion multifocale d'images , nous avons choisi d'utiliser la transformée en ondelettes discrète en se basant sur les réseaux de neurones convolutifs.

Nous avons d'abord implémenté les algorithmes conventionnels de fusion d'images dans le domaine de transformée en ondelettes discrètes 2D associées à l'analyse multirésolution. Les images originales à fusionner sont des images monofocus, l'image résultantes est une image multifocus.

Nous avons ensuite étudié et implémenté l'algorithme de fusion en appliquant un réseau CNN. L'objectif était de tirer profit des performances des CNN. Les résultats obtenus montrent la supériorité des algorithmes de fusion à base de CNN, en terme de temps de calcul et de qualité visuelle.

Perspectives

Malgré les progrès et les améliorations apportés par le CNN, il reste cependant plusieurs points à développer tel que le cas des images corrompues par le brut et le cas de corrélation entre les pixels des images.

Références

- [1] Kaazaoui, A et Kaazaoui,K .2018. « La fusion d'image multifocale. »Mémoire master, Université Ahmed Draia - Adrar,2017/2018.
- [2] Flissi, S et Fettouhi,L .2016. « Fusion d'images de la Kinect par la transformée en ondelettes. » Mémoire magister, université Mouloud Mamri de Tizi-Ouzou, 25 / 09 / 2016.
- [3]Tavard,F.2012. « Recalage et fusion d'informations multimodales pour l'optimisation de la thérapie de resynchronisation cardiaque »,thèse de doctorat ,université de Rennes1, 24 avril 2012.
- [4] Ghanima, Dj.2015. « Comparatif de méthodes avancées pour la fusion d'images satellites »thèse de doctorat , université d'Oran des sciences et de la technologieUSTO-MB, 2014/2015.
- [5] Ben guedoudj,A.2019. « Techniques de fusion des images multimodales : application aux images médicales.»,thèse de doctorat, Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj, 2019.
- [6]F. E. A. El-Samie, M. M. Hadhoud, and S. E. El-Khamy, "Image Super-Resolution and 113 Applications," FL, Boca Raton: CRC Press, 2013.
- [7] R. Singh and A. Khare, "Fusion of multimodal medical images using Daubechies complex wavelet transform – A multiresolution approach," Inf. Fusion, vol. 19, pp. 49– 60, 2014.
- [8] M. Turk and A. Pentland, "Eigenfaces for Recognition," J. Cogn. Neurosci, vol. 3, no. 1, pp. 71–86, 1991.
- [9] Y. Li, Y. Sun, X. Huang, G. Qi, M. Zheng, and Z. Zhu, "An Image Fusion Method Based on Sparse Representation and Sum Modified-Laplacian in NSCT Domain," Entropy, vol. 20, no. 7, pp. 522, 2018.
- [10]Tichrafi,M et Bouchachia,M.2013."Fusion des images cérébrales par la transformée en ondelette discrète(DWT)" .Mémoire master , Centre universitaire d'Ain Témouchent, 2013/2014
- [11] Benneni,R.2020. « Système de sécurité biométrique multimodal utilisant l'iris et le visage" .Mémire master, Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj, 8 septembre 2020
- [12]Mokri, MZ.2017. « Classification des images avec les réseaux de neurones convolutionnels. »mémoire de master, Université Abou Bakr Belkaid Tlemcen , 03/07/2017.

[13] Bonazza, P. 2019. « Système d'identification biométrique multimodale par imagerie, dédié au contrôle d'accès », Thèse de doctorat, Université de Bourgogne, 21 juin 2019.

[14] Cornioley, P. 2018. « Intégration d'un module d'apprentissage profond dans l'architecture logicielle d'un SIG Web », pour l'obtention du grade de Maître en science, Université de Sherbrooke, 2018.

[15] Berkani, C et Gatrani, M. 2012. « Détection et Reconnaissance de Visage. » Mémoire master, Université Larbi Ben Mhidi OumEl Bouaghi, 2011/2012.

[16] Guerromi, N et Gatrani, M. 2019. « Segmentation automatique par apprentissage profond de la colonne vertébrale scoliotique à partir d'images de résonance magnétique. » Mémoire pour exigence partielle à laboratoire de la maîtrise, université du Québec, 26 avril 2019.

[17] Vidéo: « Convolutional Neural Network in matlab »

<https://www.youtube.com/watch?v=ZOXOwYUVCqw>

[18] <https://openclassroom.com>

[19] Pdf : « réseau à convolution avancés et architectures convolutives modernes »,

https://http://info.usherbrooke.ca/pmjodoin/cours/ift780/notes/03_CNN_avance_2pages.pdf.com

[20] Dahmane, Kh. 2020. « Analyse d'images par méthode de Deep Learning appliquée au contexte routier en conditions météorologiques dégradées ». Thèse de doctorat, Université Clermont Auvergne, 17 juin 2020.

[21] Bonazza, P. 2019. « Identification » Système de sécurité biométrique multimodal par imagerie, dédié au contrôle d'accès. » Thèse de doctorat, L'UNIVERSITÉ DE BOURGOGNE, 21 /Juin /2019.

[22] Pdf : « Réseau pour l'apprentissage profond » <https://cours.etsmtl.ca>

[23] Moravie, ph G. 1997. « Parallélisation d'une méthode de compression d'images: Transformée en Ondelettes, Quantification Vectorielle et Codage d'Huffman. » Thèse de doctorat, L'institut national polytechnique de Toulouse, 17 Juillet 1997.

[24] P. Carré, « Construction et Analyse de Transformées Discontinues en Ondelettes : Spécificité de l'Image et de la Couleur, » Mémoire pour l'obtention de l'habilitation à diriger des recherches, Université de Poitiers, 2011.