

الجمهورية الجزائرية الديمقراطية الشعبية

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة محمد البشير الإبراهيمي - برج بوعريريج

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

Faculté des Sciences et de la Technologie

Département D'Electronique

MÉMOIRE

Présenté pour l'obtention du diplôme de MASTER

En : Télécommunications

Spécialité : Systèmes des télécommunications

Par : - Mr Azzoug Mohamed

-Mr Belaidi Aymen

Sujet

Algorithmes de Prétraitement d'Images à Multi
Copies Bruitées

Soutenu publiquement, le / / , devant le jury composé de :

M.Talbi Mohamed Lamine

MCA

Univ-BBA

Président

Mme. Sid Ahmed Soumia

MCB

Univ-BBA

Examineur

Mme. Messali Zoubeida

PROF

Univ-BBA

Encadreur

Année Universitaire 2022/2023

Remerciements

Tout d'abord, nous voudrions remercier Dieu Tout-Puissant,

Qui nous a donné force et patience pour accomplir cet humble travail.

*La première personne que nous voudrions remercier ma superviseure, Mme Messali
Zubeida, pour ses conseils et sa confiance*

*Patience et ses bonnes explications ont été une grande contribution sans laquelle ce
travail n'aurait pas été possible.*

*Nous remercions également très sincèrement les membres du jury pour l'intérêt qu'ils
ont porté à nos recherches en acceptant d'examiner nos travaux et de les enrichir de
leurs propositions.*

Enfin, merci à Ghofran Benqana et Sobhi Mohamed Ali.

Dédicace

Je dédie ce modeste travail à :

À mes chers parents, que nulle dédicace ne puisse exprimer mes Sincères

Sentiments,

*Pour leur patience illimitée, leur encouragement continu, leur aide, en témoignage
de mon profond amour et respect pour leurs grands sacrifices*

À ma chère sœur «Mina».

À mes frères « Akram et Abed alsamed »

À mon chère binôme «Azzoug Mohamed »

*Et à tous ceux qui ont contribué de près ou de loin pour que ce travail soit possible,
je vous dis merci.*

Aymen

Dédicace

Tout d'abord, je tiens à remercier Dieu De m'avoir donné la force et le courage.

Je dédie cet humble travail à :

À ceux qui m'ont élevé et enseigné « ma mère et mon père ».

Et à mon grand-père « que Dieu ait son âme » et ma grand-mère, et A mon oncle et la femme de mon oncle.

À mes frères et sœurs « Anfal, Kawthar, Rahil, Mourad ».

À mon ami et partenaire dans cette mémoire « Aymen Belaidi ».

Tous mes amis.

Merci pour votre soutien et vos encouragements.

Mohamed

Résumé

La super résolution d'image est un ensemble de techniques de traitement d'image utilisées dans la vision automatisée pour améliorer la précision des images corrompues. Ces dernières années, les techniques d'apprentissage en profondeur ont fait de grands progrès pour atteindre des images de qualité supérieure. Dans cette étude, nous identifions les améliorations récentes des techniques d'imagerie à haute résolution en utilisant des méthodes d'apprentissage en profondeur. Plus précisément, nous implémentons les algorithmes deep Learning : VDSR et CAR dans le cas d'une seule et multi copies d'images. Une étude comparative sera menée pour calculer le rapport du signal max sur bruit PSNR et l'indice de similarité structurelle (SSIM). Les résultats obtenus montrent l'efficacité des deux algorithmes, notamment l'algorithme CAR.

Abstract

Image Super resolution is a set of image processing techniques used in computer vision to improve the accuracy of corrupted images. In recent years, deep learning techniques have made great strides to achieve higher quality images. In this study, we identify recent improvements in high-resolution imaging techniques using deep learning methods. More specifically, we leverage and implement deep learning algorithms: VDSR and CAR in the case of single and multiple image copies. A comparative study will be carried out to calculate the Peak signal to noise ratio (PSNR) and the structural similarity index (SSIM). The obtained results show the efficiency of the two algorithms, in particular the CAR algorithm.

ملخص

الدقة الفائقة للصور هي مجموعة من تقنيات معالجة الصور المستخدمة في رؤية الكمبيوتر لتحسين دقة الصور التالفة. في السنوات الأخيرة، خطت تقنيات التعلم العميق خطوات كبيرة لتحقيق صور ذات جودة أعلى. في هذه الدراسة، نحدد التحسينات الحديثة في تقنيات التصوير عالي الدقة باستخدام أساليب التعلم العميق. وبشكل أكثر تحديداً، نقوم بالاستفادة من خوارزميات التعلم العميق وتنفيذها: VDSR و CAR في حالة نسخ الصور الفردية والمتعددة. سيتم إجراء دراسة مقارنة لحساب النسبة المرجعية القصوى للوضوء (PSNR) ومؤشر التشابه الهيكلي (SSIM). تظهر النتائج التي تم الحصول عليها كفاءة الخوارزميتين، ولا سيما خوارزمية CAR.

Table de Matières

Introduction Générale	I
Chapitre 1 : Principes de Base de Super Résolution d'Image	3
1.1. Introduction	4
1.2. Méthodes d'amélioration d'image	4
1.2.1. Filtrage :	4
1.2.2. Super-résolution	5
1.2.3. Fusion d'images	5
1.3. Méthodes conventionnelles de super résolution	5
1.3.1. L'interpolation bicubique	5
1.3.2. L'interpolation bilinéaire	6
1.3.3. L'interpolation de plus proche voisin Nearest Neighbor	6
1.4. Super Résolution d'Image à Base de Deep Learning (DL)	6
1.4.1. VDSR (Very Deep Super Resolution)	7
1.4.2. CAR (Content Adaptive Resampler)	8
1.5. Critères d'Évaluation	11
1.6. Conclusion	12
Chapitre 2 : Concepts de base de l'apprentissage profond	13
2.1. Introduction	14
2.2. Apprentissage Automatique (Machine Learning ML)	14
2.2.1. Apprentissage supervisé	15
2.2.2. Apprentissage non supervisé	15
2.3. Ensemble de données (Datasets) ou jeux de données	15
2.4. Apprentissage profond	16
2.5. Réseaux neuronaux	16
2.5.1. L'architecture	16
2.5.2. Les réseaux de neurones convolutifs	16
2.5.3. Fonction d'activation	17
2.6. Réseau neuronal convolutif (Convolutional Neural Network CNN)	18
2.6.1. Principe de fonctionnement du réseau de neurones convolutifs	20
2.7. Conclusion	21
Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond	22
3.1. Introduction	23

3.2. Matériel utilisée.....	23
3.3. Jeu de données	23
3.4. Etape d'implémentation des expériences de simulation	27
3.4.1. VDSR.....	27
3.4.2. CAR.....	27
3.5. résultat et discussion	27
3.5.1. le cas d'une seule copie d'image (SSIR)	28
3.5.1.1. VDSR	28
3.5.1.2. CAR.....	31
3.5.2. Cas d'images à multi copies (MISR)	34
3.5.2.1. VDSR	34
3.5.2.2. CAR.....	35
3.6. Conclusion	37
Conclusion Générale	38

List des Figures

Figure 1.1 : Image EM bruitée (a) et sa version d'ébruitée (b).....	5
Figure 1. 2 : Architecture du SRCNN.....	7
Figure 1. 3 : Architecture du réseau VDSR	8
Figure 1. 4 : Architecture du réseau CAR.....	9
Figure 1. 5 : Structure d'un bloc de fusion d'images dans le domaine spatial.....	10
Figure 1. 6 : Fusion de deux images par DWT	10
Figure 2. 1 : Apprentissage supervisé	15
Figure 2. 2 : Architecture des réseaux de neurones convolutifs.....	16
Figure 2. 3 : Description des opérations de convolution sur les régions d'image couleur	19
Figure 2. 4 : Couche de regroupement (max Pooling layer)	19
Figure 2. 5 : Couche entièrement connecté (Fully connected layer)	20
Figure 3. 1 : images haut résolution original.....	26
Figure 3. 2 : images bruitées	26
Figure 3. 3 : images fissionnées	27
Figure 3. 4 : Etapes d'implémentation de VDSR.....	28
Figure 3. 5 : Schéma de VDSR	35
Figure 3. 6 : Schémas de CAR	36

List des Tableaux

Tableau 2. 1 : Fonctions d'activation usuelles	17
<i>Tableau 3. 1 : Base de données LIVE1</i>	<i>24</i>
<i>Tableau 3. 2 : Base de données set 5</i>	<i>25</i>
<i>Tableau 3. 3 : Base de données set 14</i>	<i>25</i>
<i>Tableau 3. 4 : Base de données images bruitées.....</i>	<i>26</i>
<i>Tableau 3. 5 : Base de données images fissionnées.....</i>	<i>27</i>
<i>Tableau 3. 6 : les résultats de PSNR et SSIM de Noisy1</i>	<i>29</i>
<i>Tableau 3. 7 : les résultats de PSNR et SSIM de set 5</i>	<i>29</i>
<i>Tableau 3. 8 : les résultats de PSNR et SSIM de set 14</i>	<i>29</i>
<i>Tableau 3. 9 : les résultats de PSNR et SSIM de live1.....</i>	<i>30</i>
<i>Tableau 3. 10 : les résultats moyens de PSNR et SSIM de set 5</i>	<i>31</i>
<i>Tableau 3. 11 : les résultats moyens de PSNR et SSIM de set 14</i>	<i>31</i>
<i>Tableau 3. 12 : les résultats moyens de PSNR et SSIM de live1.....</i>	<i>31</i>
<i>Tableau 3. 13 : les résultats de PSNR et SSIM de Noisy1</i>	<i>31</i>
<i>Tableau 3. 14 : les résultats de PSNR et SSIM de set 5</i>	<i>32</i>
<i>Tableau 3. 15 : les résultats de PSNR et SSIM de set 14</i>	<i>32</i>
<i>Tableau 3. 16 : les résultats de PSNR et SSIM de live1.....</i>	<i>33</i>
<i>Tableau 3. 17 : les résultats moyens de PSNR et SSIM de set 5</i>	<i>34</i>
<i>Tableau 3. 18 : les résultats moyens de PSNR et SSIM de set14.....</i>	<i>34</i>
<i>Tableau 3. 19 : les résultats moyens de PSNR et SSIM de Live 1.....</i>	<i>34</i>
<i>Tableau 3. 20 : les résultats de PSNR et SSIM de Noisy_fused.....</i>	<i>34</i>
<i>Tableau 3. 21 : les résultats de PSNR et SSIM des images fissionnées</i>	<i>35</i>
<i>Tableau 3. 22 : les résultats de PSNR et SSIM Noisy_fused.....</i>	<i>Erreur ! Signet non défini.</i>

Abréviations et Symboles

CAR	Content adaptive resampler (Ré échantillonnage adaptatif du contenu)
CNN	Convolutional Neural Network (Réseau de neurones convolutifs)
DL	Deep Learning (L'apprentissage en profondeur)
EM	Electron microscopy (microscopie électronique)
EM	Electron microscopy (microscopie électronique)
HR	High resolution (haute resolution)
IA	Intelligence artificielle
LR	Low Résolution (basse resolution)
MISR	Multi images Super-Résolution (super-résolution multi-images)
ML	Machine Learning (Apprentissage automatique)
NN	Neural network (réseau neuronal)
PSNR	Peak Signal-to-Noise Ratio (Rapport signal/bruit maximal)
SISR	Single Image Super-Résolution (super-résolution d'image unique)
SR	Super-résolution
SSIM	Structural Similarité (Similitude structurelle)
VDSR	Very Deep super-résolution network (réseau super-résolution très profond)

Introduction Générale

Dans le domaine de la vision par ordinateur et du traitement d'images, la super-résolution d'image (ISR) fait référence au processus de reconstruction d'images haute résolution à partir d'entrées basse résolution [1]. Cependant, dans les scénarios du monde réel, les images sont souvent corrompues par le bruit pendant le processus d'acquisition ou de transmission, ce qui pose un défi important pour les algorithmes de super-résolution. Pour résoudre ce problème, l'apprentissage en profondeur est devenu une approche puissante pour obtenir une super-résolution de haute qualité dans des images bruitées.

Les méthodes d'apprentissage en profondeur, en particulier les réseaux de neurones convolutifs (Convolutional Neural Network CNN), ont révolutionné le domaine de la vision par ordinateur [2] en tirant profit de leur capacité à apprendre des modèles et des représentations complexes à partir d'ensembles de données à grande échelle. Dans le contexte de la super-résolution dans les images bruitées, les modèles d'apprentissage en profondeur ont montré des performances remarquables dans la restauration des détails fins et la réduction des artefacts et de bruit.

Dans beaucoup de situations, multicopies d'une seule image sont disponibles, tel que le cas des images radar à ouverture synthétiques (SAR) [3] les images de microscopie électronique EM. On doit donc tirer profit de toutes les copies de l'image et les exploiter en proposant des structures et des architectures de combinaison, dans l'optique d'améliorer la qualité d'image d'avantage. Notre travail s'inscrit dans le cadre de la super résolution d'images à multi copies bruitées. Plus précisément, nous allons traiter des images affectées par un bruit gaussien additif, avec différents niveaux de puissance. Notre travail consiste à implémenter des algorithmes de fusion en amont de la chaine de traitement, pour combiner toutes les copies d'une même image, puis appliquer deux réseaux deep Learning(DL) qui ont prouvé leur efficacité en super résolution : le réseau Very Deep Super Resolution VDSR, et le réseau échantillonnage adaptatif au contenu (Content Adaptif Resampler CAR). Les cas d'une seule copie bruitée (Single Image Super Resolution ISR) et le cas des images à multi copies bruitées (Multi Image SR : MISR) seront considérés dans notre étude. Plusieurs expériences de simulation seront présentées pour montrer l'intérêt d'utiliser le deep Learning en super résolution (SR) et l'intérêt d'exploiter les copies disponibles d'une même image. L'efficacité des architectures proposées de SR est justifiée quantitativement et qualitativement.

2 Organisation du Manuscrit

Le présent manuscrit est constitué de trois chapitres en plus de cette introduction générale et une conclusion générale avec la liste de références à la fin de ce manuscrit.

Le premier chapitre introduira le problème de super résolution des images. Les algorithmes conventionnels d'interpolation, à savoir : bicubique, bilinéaire et le plus proche voisin, seront décrites en premier lieu. Les algorithmes de super résolution basée sur des réseaux deep Learning seront exposés en détail dans la deuxième partie de ce chapitre.

Le deuxième chapitre présentera les principes de bases de l'apprentissage profond (deep Learning (DL)). Les algorithmes DL appliqués en super résolution : Very Deep Learning VDSR et Content Adaptive Resampler CAR, seront étudiés dans la deuxième partie de ce chapitre.

Le troisième chapitre sera consacré à l'étude d'implémentation des algorithmes SR basé sur le deep Learning, avec deux cas distincts : cas d'une seule copie détériorée par le bruit et le sous échantillonnage (Single Image SR : SISR) et le cas de multi copies bruitées (MISR). Deux réseaux seront implémentés : VDSR et CAR. Les deux réseaux seront testés sur différentes bases de données. L'étude comparative quantitative est effectuée en calculant le rapport maximum du signal sur bruit (Peak signal to noise ratio PSNR) ainsi que l'indice de similarité de structure (structural similarity index SSIM).

Chapitre 1 : Principes de Base de Super Résolution d'Image

Résumé

Ce chapitre traite des techniques de super-résolution, qui consistent à augmenter la résolution et les détails d'une image basse résolution pour obtenir une version haute résolution plus nette. Le processus comprend l'acquisition d'images basse résolution, l'extraction de caractéristiques, la création d'un modèle d'apprentissage automatique, la formation du modèle et l'application d'une super résolution pour générer des images haute résolution. Différentes méthodes et techniques, conventionnelles l'interpolation et les réseaux de neurones profonds, seront exposés dans ce chapitre.

SOMMAIRE CHAPITRE 1 :

<u>1.1. Introduction</u>	4
<u>1.2. Méthodes d'amélioration d'image</u>	4
<u>1.3. Méthodes conventionnelles de super résolution</u>	5
<u>1.4. Super Résolution d'Image à Base de Deep Learning (DL)</u>	6
<u>1.5. Critères d'Évaluation</u>	11
<u>1.6. Conclusion</u>	12

1.1. Introduction

La super résolution d'image (Single Image Super Résolution **SISR**) est un processus qui consiste à augmenter la résolution d'une image à partir de sa version basse résolution (Low Résolution **LR**), en utilisant des algorithmes de traitement d'image. Ces algorithmes peuvent être basés sur l'apprentissage en profondeur (Deep Learning), qui permet de reconstruire des détails manquants et d'obtenir une image plus nette et plus détaillée.

L'amélioration d'image, quant à elle, vise à améliorer la qualité générale de l'image en réduisant le bruit, en améliorant la netteté et en augmentant le contraste. Cette technique peut également être réalisée à l'aide d'algorithmes de traitement d'image et d'apprentissage automatique. Dans beaucoup de situations, plusieurs copies détériorées d'une même image sont disponibles, tel que le cas des images radar à ouverture synthétique (synthétique aperture radar **SAR**) [5] et les images à microscopie électronique (Electron Microscopie) De ce fait, l'exploitation de toutes les copies détériorées va permettre d'améliorer considérablement la qualité d'image.

Dans ce chapitre, nous détaillerons les méthodes d'amélioration et les méthodes conventionnelles de la super résolution. Les algorithmes de super résolution à base de deep learning, seront exposés à la deuxième partie de ce chapitre. Deux cas sont pris en considération : le cas de super résolution à une seule copie (single image super résolution **SISR**) et le cas de super résolution à multi-copies (Multi Image SR **MISR**).

1.2. Méthodes d'amélioration d'image

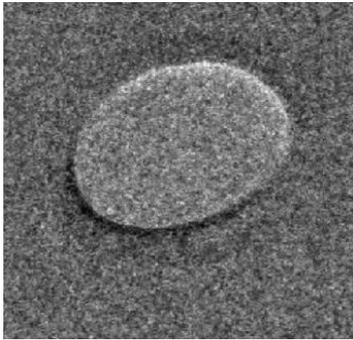
Effectivement, Il existe plusieurs méthodes pour améliorer la qualité d'une image, à savoir :

- Le filtrage,
- La super-résolution,
- La fusion d'images

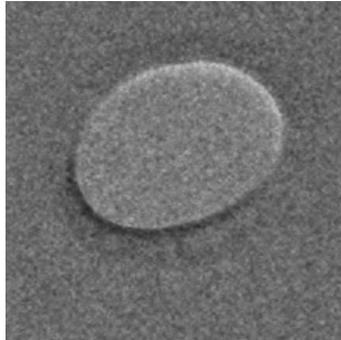
1.2.1. Filtrage :

Le filtrage est une technique qui permet de réduire le bruit d'une image en utilisant des filtres numériques. Les filtres peuvent être linéaires, tels que les filtres moyenneurs ou médian. Le filtrage peut également être utilisé pour améliorer la netteté de l'image en appliquant des filtres de renforcement de bord [6] ou des méthodes basées sur la transformée en ondelettes [7]. La Figure 1.1 illustre un exemple d'image filtrée par le filtre gaussien. La Figure montre une image EM (électron microscopie) bruitée, le bruit étant additif gaussien avec un rapport signal sur bruit égale à $14.40dB$, et

le résultat de filtrage à base d'ondelettes [7] (Il est à noter que l'image EM est prise par un microscope électronique de l'institut INSERM d'Orsay, France.



(a) $SNR = 14.40dB$



(b) $SNR = 16,75 dB$

Figure 1.1 : Image EM bruitée (a) et (b) sa version débruitée

1.2.2. Super-résolution

La super-résolution est une technique de traitement d'images qui permet d'augmenter la résolution d'une image à partir de plusieurs images de faible résolution (Low résolution LR). Cette technique peut être utilisée pour augmenter la qualité des images et pour améliorer la netteté des détails. La super-résolution peut être basée sur des techniques de reconstruction d'image, telles que les méthodes de super-résolution par interpolation ou sur des techniques d'apprentissage en profondeur [8], telles que le premier réseaux appliqué en SR : Very Deep learning SR (VDSR), le réseau de neurones convolutifs (SRCNN) et le réseau CAR (content adaptive resampler). Notons que VDSR et CAR, seront implémentés et discutés en chapitre 3.

1.2.3. Fusion d'images

La fusion d'images est une technique qui permet de combiner plusieurs images pour créer une image composite qui contient des informations à partir de toutes les images d'origine. Cette technique peut être utilisée pour améliorer la qualité de l'image en éliminant le bruit et en améliorant la netteté des détails. Cette technique a son utilité dans le cas où nous disposons de plusieurs copies détériorées d'une même image. [9]

1.3. Méthodes conventionnelles de super résolution

1.3.1. L'interpolation bicubique

Est une méthode couramment utilisée pour la super-résolution d'images. Elle consiste à utiliser une fonction polynomiale pour interpoler les pixels manquants dans l'image basse résolution LR afin

d'obtenir une image haute résolution [10] Cette fonction est déterminée en utilisant les valeurs de pixels voisins dans l'image basse résolution LR.

1.3.2. L'interpolation bilinéaire

Est souvent utilisée comme première étape dans les algorithmes de super résolution, qui visent à générer des images haute résolution (HR) à partir d'entrées basse résolution (LR). En super résolution, l'interpolation bilinéaire est utilisée pour mettre à l'échelle de l'image basse résolution à une résolution plus élevée en insérant des pixels supplémentaires entre les pixels d'origine [11].

1.3.3. L'interpolation de plus proche voisin Nearest Neighbor

L'interpolation de Nearest Neighbor est une méthode simple et rapide qui consiste à déterminer pour chaque point de l'image interpolée le pixel le plus proche de l'image originale, puis à attribuer la valeur de ce pixel au point de l'image interpolée. Cette méthode peut être utilisée pour réduire la taille d'une image en supprimant des pixels, ou pour agrandir une image en dupliquant les pixels existants.

Cependant, ces méthodes d'interpolation, peuvent produire des images floues ou irréalistes car elles ne capturent pas la véritable structure sous-jacente de l'image. Récemment, beaucoup de travaux proposés dans la littérature, font appel à l'apprentissage profond pour surmonter les limitations des méthodes conventionnelles.

Dans ce qui suit, nous détaillerons quelques algorithmes SR à base de deep learning (DL).

1.4. Super Résolution d'Image à Base de Deep Learning (DL)

La super-résolution d'image unique (SISR) est une technique utilisée pour augmenter la résolution et la qualité d'une seule image basse résolution (LR). L'objectif de SISR est de générer une version haute résolution (HR) de l'image d'entrée qui contient plus de détails et apparaît plus nette à l'œil humain.

En revanche, les méthodes basées sur l'apprentissage utilisent des techniques d'apprentissage automatique, telles que les réseaux de neurones à convolution (Convolutional Neural Network (CNN)), pour apprendre le mappage entre les images basse résolution (LR) et haute résolution (HR). En s'entraînant sur un grand ensemble de données de paires d'images basse résolution et haute résolution, le CNN peut apprendre à extraire et reconstruire des détails haute fréquence à partir de l'entrée basse résolution. Les avantages du réseau CNN sont: un taux d'erreur généralement bon très petit, Outil disponible dans les environnements datamining, robuste par rapport au bruit et données

manquantes, ce qui le rend adapté au problème de la super résolution. Le réseau CNN est aussi facile à combiner avec d'autres architectures. Parmi les inconvénients de CNN : -l'apprentissage du réseau est très long, -plusieurs paramètres qu'il faut gérer (architecture, poids de connections, pas de gradients). L'application du CNN en super résolution est à travers le réseau SRCNN. La Figure 1.2 montre l'architecture globale du SRCNN qui se base sur une succession de couches à convolution avec des filtres pour extraire les caractéristiques (feature maps), couches non linéaire (fonction d'activation Relu, comme nous allons détailler dans chapitre 2) et couche de connexion (full connecting layer FL).

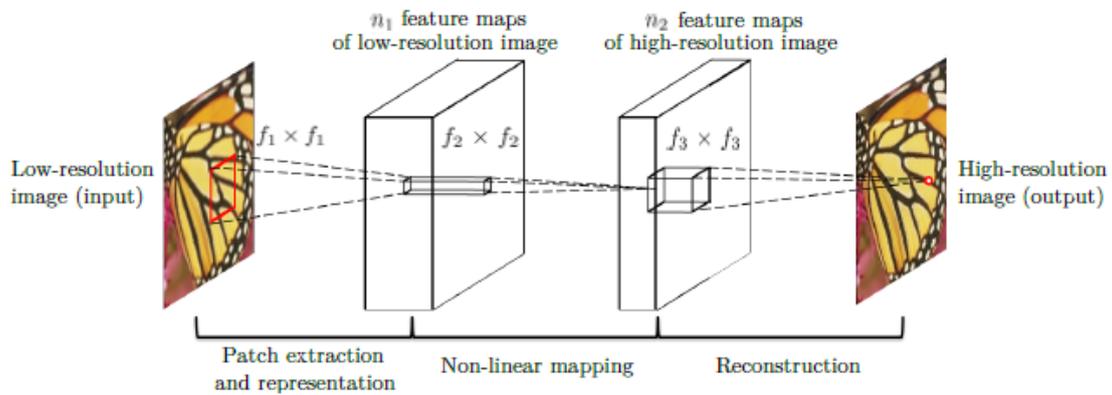


Figure 1. 2 : Architecture du SRCNN [12]

Le SISR a de nombreuses applications pratiques, telles que le domaine médical pour améliorer les images médicales, dans le domaine de la surveillance pour améliorer les images de surveillance de faible qualité et dans l'industrie du divertissement pour améliorer la qualité visuelle des médias numériques. [13]

Dans notre étude, nous avons implémenté deux réseaux DL appliqués en super résolution : VDSR (very deep SR) qui est le premier réseau utilisé en SR et le réseau à ré échantillonnage du contenu (Content Adaptive Resampler CAR) qui est une version améliorée du premier réseau.

1.4.1. VDSR (Very Deep Super Resolution)

Le VDSR est une méthode d'apprentissage profond utilisé en super résolution. Il y a des couches cachées (20 couches environ, plus que le SRCNN qui a seulement trois couches. La Figure 1.3 illustre l'architecture du VDSR. Nous remarquons que la structure dispose de plusieurs couches de convolution et de couches non linéaires (fonction d'activation Relu) : le processus consiste à extraire l'image résiduelle (détails de différence entre l'image HR et l'image LR générée. Les images

résultantes des couches de convolution, représentent les caractéristiques (cartes) d'images. Puis, additionner cette résiduelle à l'image LR à la fin de la chaîne, pour obtenir l'image SR finale [14].

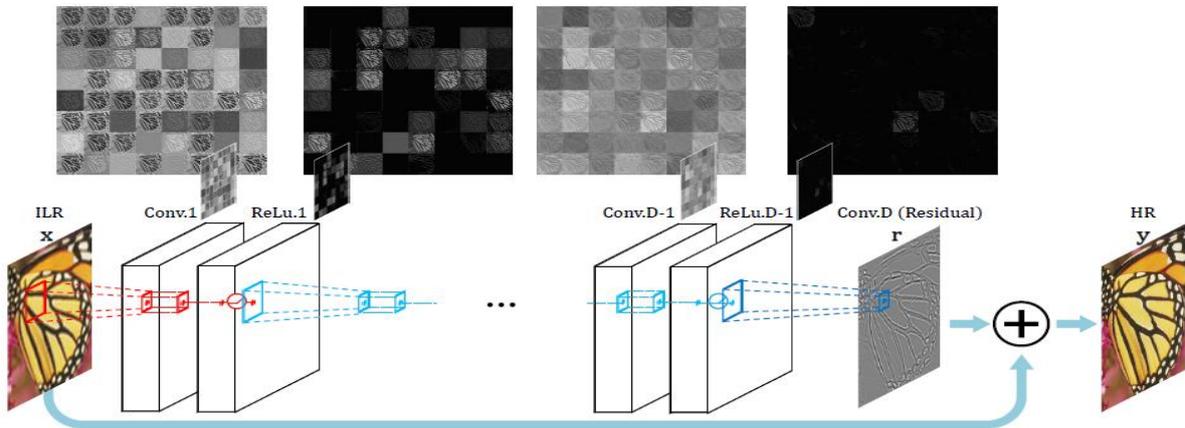


Figure 1. 3 : Architecture du réseau VDSR [14]

1.4.2. CAR (Content Adaptive Resampler)

Dans le contexte de la super résolution, le Content Adaptive Resampler (CAR) est un réseau utilisé pour améliorer la qualité des images détériorées. Le réseau CAR analyse le contenu local de l'image basse résolution pour identifier les détails, les contours et les structures importantes. Il utilise ensuite ces informations pour guider le processus de super résolution afin de préserver ces caractéristiques lors de la génération de l'image de haute résolution. Un aspect clé du CAR dans la super résolution est l'utilisation de techniques d'interpolation et de reconstruction adaptatives. Différentes parties de l'image basse résolution nécessitent des méthodes d'interpolation différentes en fonction de leur contenu. Par exemple, les régions avec des contours nécessitent des techniques d'interpolation qui préservent les détails, tandis que les régions lisses (homogènes) nécessitent des méthodes plus douces pour éviter les artefacts. L'efficacité de CAR est la préservation des détails importants, tels que les textures et les structures de l'image d'origine et les injecter dans l'image LR. Cela permet d'obtenir des résultats plus réalistes et plus fidèles à l'image réelle. L'architecture de CAR est illustrée dans la Figure 1.4. CAR est composé essentiellement de deux blocs : lr » échantillonneur et le réseau SR Net. Le rôle du premier bloc est la génération de la version basse résolution (LR de l'image originale (HR). Ce bloc est constitué à son tour de couches de convolution et de couches et fonction Relu pour extraire les poids et l'image résiduelle. La sortie de ce bloc est l'image LR qui attaque le deuxième bloc DL : SR Net. Ce bloc consiste à estimer les détails manquants et les réinjecter dans l'image LR pour estimer l'image SR [15].

Dans notre travail, nous allons implémenter les deux réseaux : VDSR et CAR dans deux cas de figure : SISR et MISR. Les images bruitées, seront aussi prises en considération, le bruit étant gaussien additif avec différents niveaux de puissances.

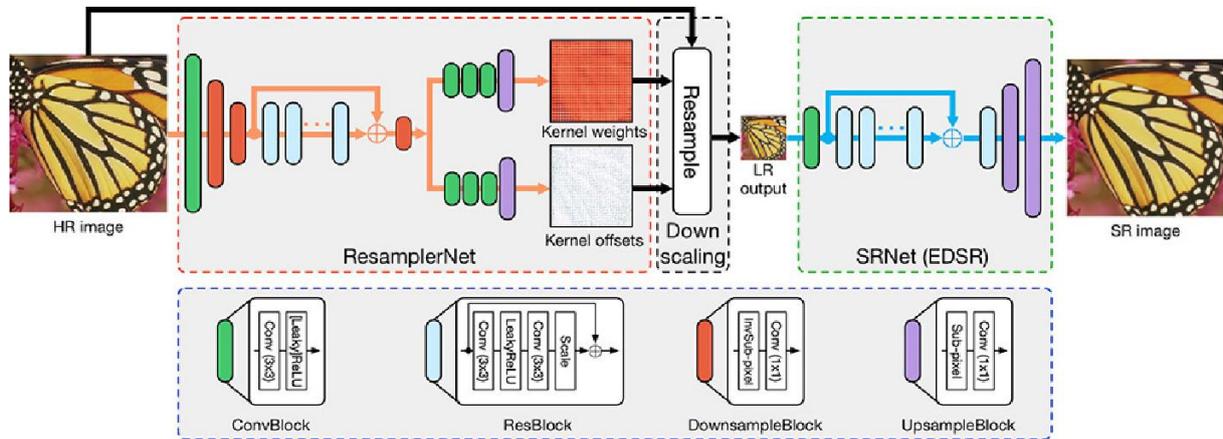


Figure 1. 4 : Architecture du réseau CAR [16]

Dans beaucoup de situations, plusieurs copies détériorées d'une même image sont disponibles. D'où la proposition des algorithmes de super résolution à multi-copies (Multi Image Super Résolution MISR).

La super-résolution multi-images (MISR)

Est une technique utilisée pour améliorer la résolution et la qualité d'une image en combinant des informations provenant de plusieurs Observations à faible résolution, tel que le cas des images radar à ouverture synthétiques (synthétique aperture radar SAR) ou les images à microscopie électronique EM (électron microscopie). L'objectif de MISR est de générer une image haute résolution qui contient plus de détails et apparaît plus nette que n'importe laquelle des images individuelles à basse résolution. MISR se base essentiellement sur des algorithmes de fusion d'images. Notre travail s'inscrit dans ce cadre.

Les approches MISR impliquent généralement deux étapes : le recalage et la fusion. Lors de l'étape de recalage, les images basses résolution sont alignées sur un cadre de référence commun. Pour notre cas, nous considérons que les différentes copies d'une même image sont déjà alignées, c'est-à-dire que le problème d'alignement (recalage n'est pas évoqué).

L'étape de fusion est accomplie en utilisant des techniques simples de moyenne ou de moyenne pondérée ou du calcul de maximum, dans le domaine spatial ou dans le domaine de transformées (traitement ponctuel) comme c'est montré sur les Figures 1.5 et 1.6.

La fusion d'image peut être effectuée dans le domaine spatial comme c'est montré sur la Figure 1.5. Les copies sont fusionnées par une des règles de fusion (maximum des copies Max, ou calcul de la moyenne (Mean) des copies. Dans notre implémentation, nous considérons la règle de fusion mean.

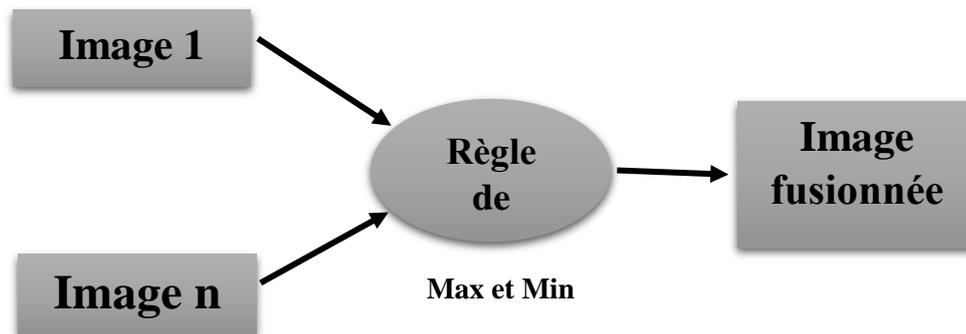


Figure 1. 5 : Structure d'un bloc de fusion d'images dans le domaine spatial

La fusion d'images peut être réalisée à l'aide de méthodes de fusion basées sur la transformée en ondelettes [17], sur la transformée de Laplace ou sur des méthodes basées sur l'apprentissage en profondeur. La fusion par ondelettes discrètes (Discret Wavelet Transform DWT) est illustrée dans la Figure 1.6.

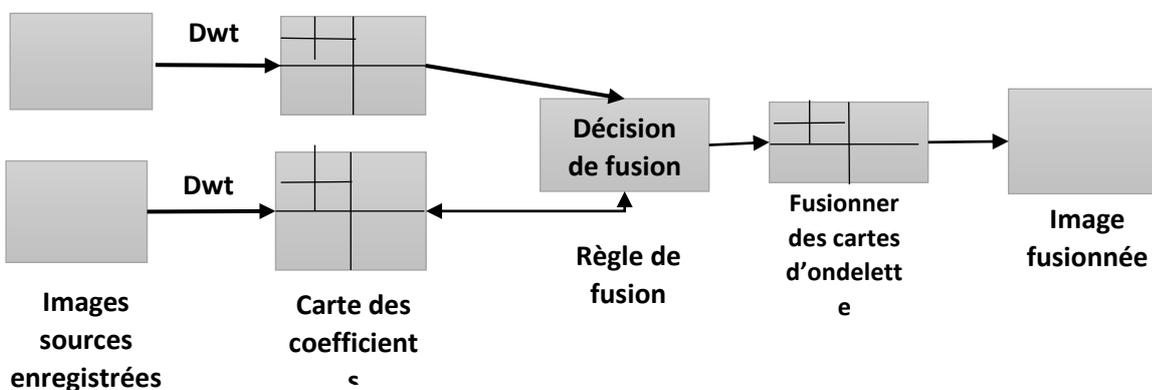


Figure 1. 6 : Fusion de deux images par DWT

1.5. Critères d'Évaluation

Dans la littérature qui traite la problématique de la super résolution, les deux critères les plus utilisés pour évaluer un algorithme sont : **PSNR** et **SSIM**.

- **PSNR Rapport** signal maximal sur bruit (Peak Signal-to-Noise Ratio)

Est une mesure quantitative de la qualité de l'image utilisée pour évaluer les performances des algorithmes SR. Elle mesure la qualité de la reconstruction en comparant la différence entre l'image originale et l'image reconstruite en termes de bruit et de distorsion [18].

Le PSNR en dB est calculé en utilisant la formule suivante :

$$PSNR = 10 \log_{10} \left(\frac{255^2}{EQM} \right) \dots (1.1)$$

$$EQM = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I_0(i,j) - I_r(i,j))^2 \dots (1.2)$$

I_r : L'image reconstruite de taille $m \times n$

i, j : représentent position du pixel ligne et colonne

I_0 : L'image originale

Plus PSNR est élevé, plus la qualité de l'image SR résultante est satisfaisante.

- **SSIM** : (Structural Similarity Index) est une mesure de la similarité structurelle entre deux images. La formule de SSIM est la suivante [19] :

$$i(x, y) = \frac{\mu_x \mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \dots (1.3)$$

$$C(x, y) = \frac{2\sigma_x \sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \dots (1.4)$$

$$S(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3} \dots (1.5)$$

μ_x, μ_y Les moyennes des images originales et reconstruite, σ_x, σ_y les écarts type et C_1, C_2 les coefficients de corrélation des deux images. SSIM est alors :

$$SSIM(x, y) = i(x, y)^\alpha \cdot C(x, y)^\beta \cdot S(x, y)^\gamma \dots (1.6)$$

Le SSIM contrôle la préservation de l'image après l'application de l'algorithme. Plus SSIM proche de 1, meilleure est le résultat de la super résolution.

Ces deux critères seront calculés pour évaluer nos résultats de simulation, comme nous allons détailler dans chapitre 3.

1.6. Conclusion

En conclusion, la super résolution des images est une technologie passionnante qui offre des possibilités d'améliorer la qualité des images dans de nombreux domaines.

Dans ce chapitre, nous avons traité le problème de la super résolution des images. Nous avons détaillé le cas de la super résolution d'une seule copie d'image (SISR) et le cas d'image à multi copies. Nous avons mis l'accent sur les algorithmes SR à base de DL, précisément : VDSR et CAR.

Les principes du deep Learning seront abordés au chapitre 2.

Chapitre 2 : Concepts de base de l'apprentissage profond

Résumé

Dans ce chapitre nous allons détailler l'apprentissage profond et ses constituants et se familiariser avec les différents vocabulaires qui seront les outils fondamentaux pour la création d'un réseau de neurones profond Deep Learning.

SOMMAIRE CHAPITRE 2:

<u>2.1. Introduction</u>	14
<u>2.2. Apprentissage Automatique (Machine Learning ML)</u>	14
<u>2.3. Ensemble de données (Datasets) ou jeux de données</u>	15
<u>2.4. Apprentissage profond</u>	16
<u>2.5. Réseaux neuronaux</u>	16
<u>2.6. Réseau neuronal convolutif (Convolutional Neural Network CNN)</u>	18
<u>2.7. Conclusion</u>	21

2.1. Introduction

L'intelligence artificielle est une spécialité scientifique qui cherche des solutions des problèmes avec une complexité logique ou un algorithme élevé [20]. Machine Learning
Domaine d'étude de l'intelligence artificielle. Par conséquent, l'apprentissage profond (en Apprentissage profond, apprentissage organisé profond, apprentissage hiérarchique) est un groupe de méthodes d'apprentissage automatique pour tenter de modéliser avec un haut niveau d'abstraction Par des structures détaillées de divers postes non linéaires.

Le principe des réseaux de neurones artificiels est né dans les années 40 à partir d'une analogie avec le système nerveux humain. Ils sont basés sur la fonction neuronale, parce que les neurones sont identifiés comme éléments cellulaires responsables du traitement de l'information dans le cerveau. Les réseaux de neurones artificiels se sont donc basés sur l'hypothèse disant que le raisonnement intelligent des êtres humains a pour origine la structure de système nerveux et donc on peut l'inculquer à un ordinateur en lui implémentant un réseau de neurones artificiels pour le rendre « intelligent », tout en sauvegardant sa puissance et sa rapidité d'exécution. L'approche neuronale c'est développé avec l'expansion de l'utilisation des outils Informatiques qui facilitent l'analyse numérique de l'information et la mise en œuvre de cette méthode.

Dans ce chapitre, nous présenterons les concepts liés à l'apprentissage profond. Et les réseaux neurones et les réseaux neurones conventionnelle.

2.2. Apprentissage Automatique (Machine Learning ML)

L'apprentissage automatique est une forme d'intelligence artificielle axée sur la création de systèmes qui apprennent ou améliorent leurs performances

L'apprentissage automatique d'aujourd'hui est utilisé partout lorsque nous traitons avec les banques, les achats en ligne ou les médias sociaux, etc. L'apprentissage automatique évolue rapidement [21].

Les algorithmes d'apprentissage automatique sont regroupés sous deux grandes classes :

2.2.1. Apprentissage supervisé

L'apprentissage supervisé est une approche de création d'intelligence artificielle (IA), où un algorithme informatique est formé sur des données d'entrée classées pour un produit donné. Le modèle est formé de manière à pouvoir détecter les modèles et les relations de base entre les données d'entrée et les étiquettes de sortie, ce qui lui permet d'obtenir des résultats précis lorsqu'il est présenté avec des données sans précédent. [22]

Dans l'apprentissage supervisé, l'objectif est de comprendre les données dans le contexte d'une question précise. La Figure 2.1 illustre le principe de l'apprentissage automatique.

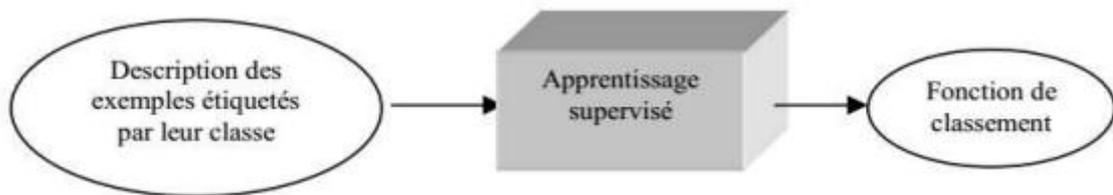


Figure 2. 1 : Apprentissage supervisé

2.2.2. Apprentissage non supervisé

L'apprentissage non supervisé est une méthode d'apprentissage automatisée qui utilise des algorithmes d'apprentissage automatique pour analyser et agréger des ensembles de données non spécifiés. Ces algorithmes détectent des modèles ou des ensembles de données cachés sans intervention humaine [23].

2.3. Ensemble de données (Datasets) ou jeux de données

Les ensembles de données sont couramment utilisés dans l'apprentissage automatique. Les ensembles de données sont des sous-ensembles de fichiers ou de données formulés en fonction des besoins d'analyse et de représentation, qui peuvent être présentés sous différentes formes (textes, formats et images) [24]. Les ensembles de données sont caractérisés par le grand nombre de données ce qui permet d'entraîner le réseau neuronal et d'organiser ces bases selon données de test et données de validation. Dans notre travail de simulation nous

nous sommes basés sur des ensembles de données utilisés aux problèmes de super résolution d'images. Nous citons à titre d'exemple : la base B100, la base DIV2K, etc. ...

2.4. Apprentissage profond

L'apprentissage profond est une caractéristique de l'intelligence artificielle qui imite le fonctionnement du cerveau humain. L'apprentissage profond est basé sur des réseaux neuronaux synthétiques, le processus d'apprentissage est profond parce que la structure des réseaux neuronaux artificiels se compose de plusieurs entrées, sorties et couches cachées. Chaque couche contient des modules qui convertissent les données d'entrée en information que la couche suivante peut utiliser pour une tâche prédictive particulière [25].

2.5. Réseaux neuronaux

2.5.1. L'architecture

L'architecture de réseau de neurones est la structure de base qui définit comment les neurones sont connectés entre eux dans un réseau de neurones artificiels.

2.5.2. Les réseaux de neurones convolutifs

Conçus spécifiquement pour traiter des données structurées en grille, tels que les images ou les vidéos [26]. La Figure 2.2 illustre l'architecture d'un réseau neuronal convolutif (CNN)

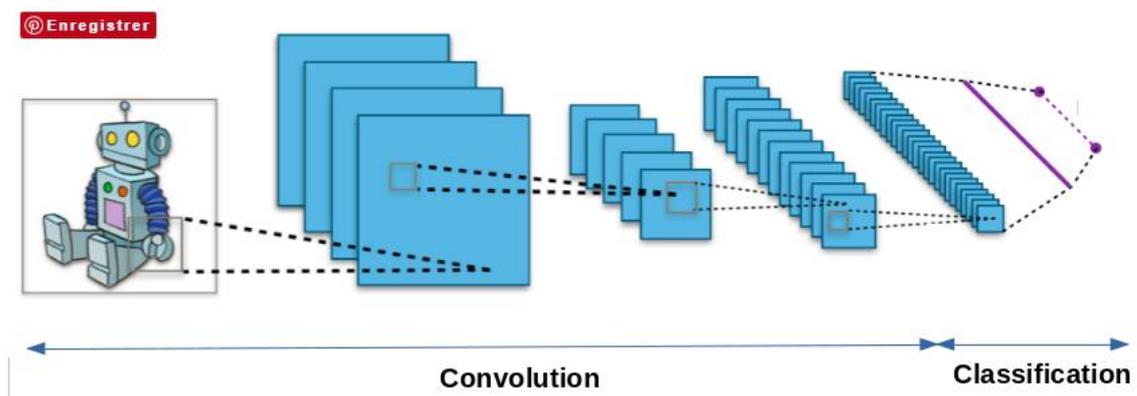


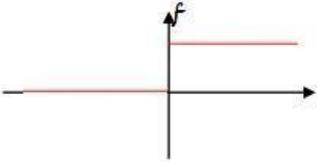
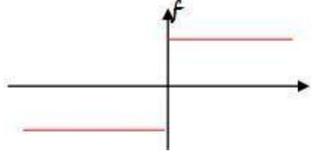
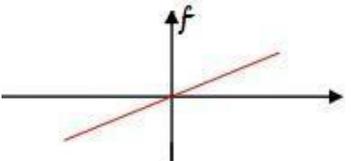
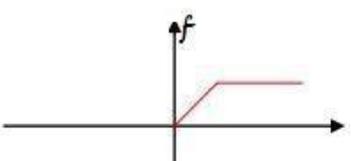
Figure 2. 2 : Architecture des réseaux de neurones convolutifs

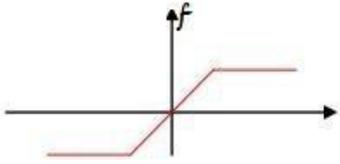
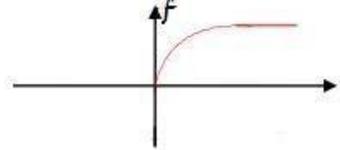
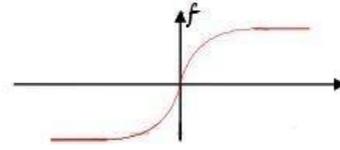
2.5.3. Fonction d'activation

Le but de la fonction d'activation (ou d'isolement, ou de transport) est d'introduire le non linéarité dans le travail des neurones et permet de prendre une décision pour avoir une sortie.

Le tableau 2.1 englobe l'ensemble des fonctions d'activations qui sont généralement utilisées [27]. Ce tableau renseigne sur l'allure de la fonction d'activation, l'équation correspondante et le nom de la fonction sous Matlab.

Tableau 2. 1 : Fonctions d'activation usuelles

Nom de la fonction	Type	Equation	Allure	Nom Matlab
Seuil	Binaire (fonction de Heaviside)	$f(x) = 0 \text{ si } x < 0$ $f(x) = 1 \text{ si } x \geq 0$		<i>Hardlim</i>
	Signe	$f(x) = 1 \text{ si } x > 0$ $f(x) = -1 \text{ si } x \leq 0$		<i>Hardlims</i>
Linéaire	Identité	$f(x) = x$		<i>Purelin</i>
	Saturé positif	$f(x, k) = 0 \text{ si } x < 0$ $f(x, k) = 1 \text{ si } x \geq 1$ $f(x, k) = kx \text{ sinon}$		<i>Satlin</i>

	Saturé symétrique	$f(x, k) = 1$ si $x < -1/k$ $f(x, k) = -1$ si $x >= 1/k$ $f(x, k) = \sin(x)$ sinon		<i>Satlin</i>
Sigmoïde	Positive (type logistique)	$f(x, k) = \frac{1}{1 + e^{-ks}}$		<i>Poslin</i>
	Symétrique (type tanh)	$f(x, k) = \frac{2}{1 + e^{-ks}} - 1$		<i>Logsig</i>

2.6. Réseau neuronal convolutif (Convolutional Neural Network CNN)

CNN est un type de réseau d'apprentissage profond multicouches pour le traitement de données matricielles qui ont un motif de grille, telles que des images, qui est inspiré par l'organisation du cortex visuel animal et conçu pour apprendre automatiquement et de manière adaptative les hiérarchies spatiales des caractéristiques, de bas à haut niveau. CNN est une construction mathématique généralement composée de trois types de couches (ou blocs de construction) : convolution, couche de correction, couche pooling, mise en commun et couches entièrement connectées [28]

- **Couches convolutives (notées Convi) :** sont constituées d'un ensemble de filtres (également appelés noyaux) qui sont appliqués à une image d'entrée. La sortie de la couche convolutive est une carte de caractéristiques, qui est une représentation de l'image d'entrée avec les filtres appliqués. Les couches convolutives peuvent être empilées pour créer des modèles plus complexes, qui peuvent apprendre des caractéristiques plus complexes à partir d'images [29]

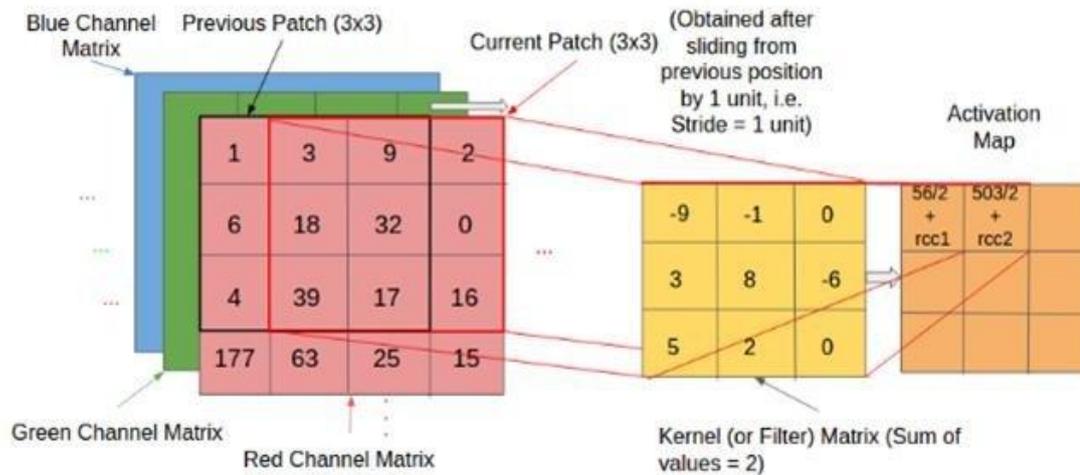


Figure 2. 3 : Description des opérations de convolution sur les régions d'image couleur [30]

- Couche de regroupement (Pooling layer):** est un type de couche convolutive utilisée dans l'apprentissage profond. Les couches de regroupement réduisent la taille spatiale de l'entrée, ce qui facilite son traitement et nécessite moins de mémoire. La mise en commun permet également de réduire le nombre de paramètres et rend l'entraînement plus rapide. Il existe deux principaux types de pooling : le pooling maximum et le pooling moyen. Le regroupement maximal prend la valeur maximale de chaque carte de caractéristiques, tandis que le regroupement moyen prend la valeur moyenne. Les couches de regroupement sont généralement utilisées après les couches convolutives afin de réduire la taille de l'entrée avant qu'elle ne soit introduite dans une couche entièrement connectée [31]. La Figure 2.4 montre un exemple du maxpooling,

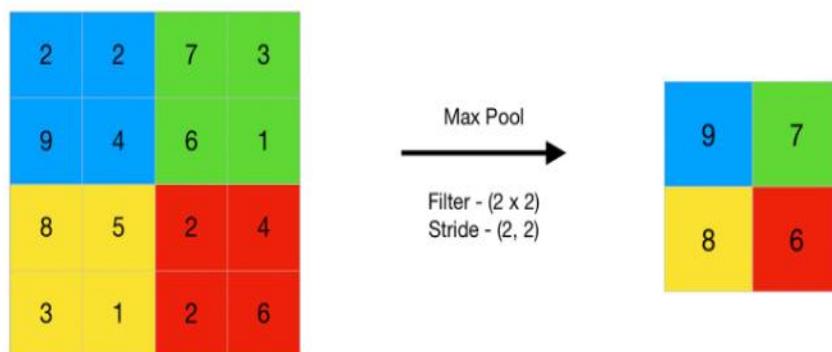


Figure 2. 4 : Couche de regroupement (max Pooling layer) [32]

- Couche entièrement connectée (Fully connected layer):** est l'une des couches les plus élémentaires d'un réseau de neurones à convolution (CNN). Comme son nom l'indique, chaque neurone d'une couche entièrement connectée est entièrement connecté à tous les autres neurones de la couche précédente. Les couches entièrement connectées sont généralement utilisées vers la fin d'un CNN, lorsque l'objectif est de prendre les caractéristiques apprises par les couches précédentes et de les utiliser pour faire des prédictions. Par exemple, si nous utilisons un CNN pour classer des images d'animaux, la dernière couche entièrement connectée pourrait prendre les caractéristiques apprises par les couches précédentes et les utiliser pour classer une image comme contenant un chien, un chat, un oiseau [33]. La Figure 2.5 montre la description de la couche (fully connected).

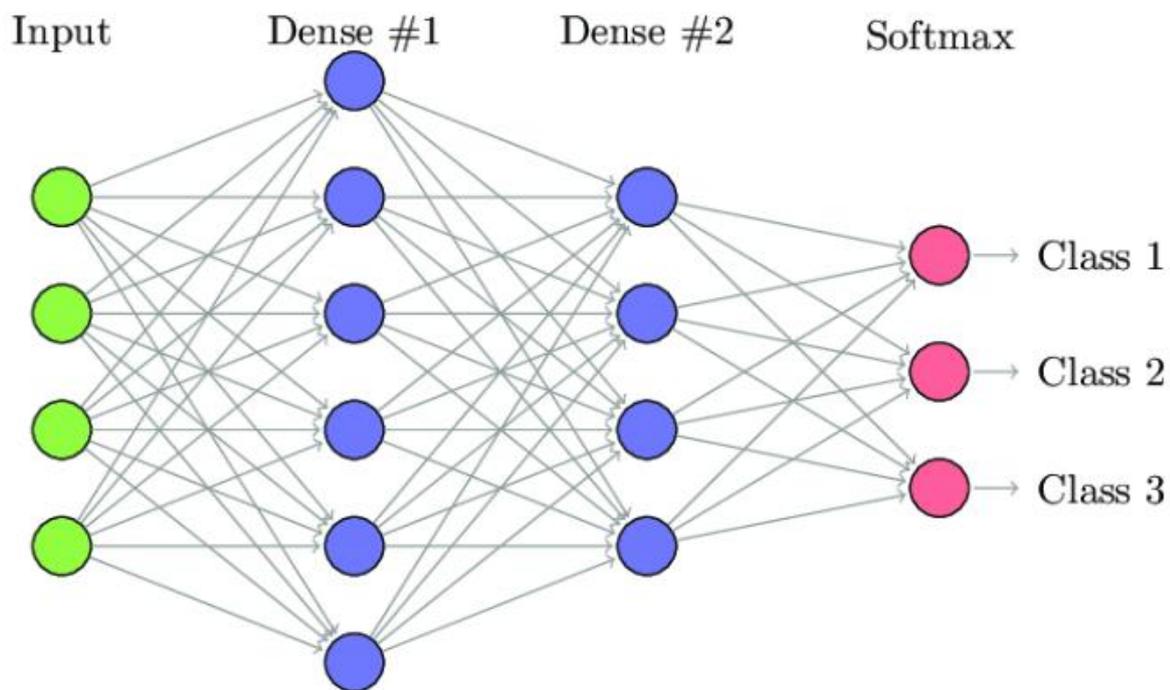


Figure 2. 5 : Couche entièrement connectée (Fully connected layer) [34]

2.6.1. Principe de fonctionnement du réseau de neurones convolutifs

Au cours du processus de formation, le CNN apprend les valeurs optimales des poids dans chaque couche par rétro propagation. L'objectif est de minimiser la fonction de perte, qui mesure la différence entre la sortie prédite et la sortie réelle. Une fois que le CNN est formé, il peut être utilisé pour classer de nouvelles images en appliquant les filtres appris à l'image d'entrée et en passant la sortie à travers la couche entièrement connectée pour produire une distribution de probabilité sur les classes.

2.7. Conclusion

Pour conclure, l'apprentissage profond peut résoudre les limitations des méthodes conventionnelles. En apprentissage profond, on valide les résultats à travers un très grand nombre de données, ce qui permet une bonne modélisation de diverses situations. Dans notre travail nous avons exploité les réseaux dans le problème de super résolution à multi copies le chapitre 3 sera consacré à la présentation de notre étude de simulation les deux cas super résolution d'image à une seule copie bruitée (signal image SR SSRI) et la super résolution à multi copie bruitée (Multi SR MISR) seront pris en considération dans notre étude

Dans le chapitre 3, nous allons traiter les deux cas de super résolution DL, SR à une seule copie et SR à plusieurs copies à deux réseaux DL qui seront implémentés CAR et VDSR.

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Résumé

Ce chapitre est consacré à la présentation et à la discussion de nos résultats de simulation. Nous mettrons en œuvre des algorithmes d'apprentissage profond super résolution : VDSR et CAR sur une copie unique (SISR) et à copies multiples (MISR). Étude comparative quantitative réalisée en termes de PSNR et SSIM.

SOMMAIRE CHAPITRE 3 :

<u>3.1.</u> <u>Introduction</u>	23
<u>3.2.</u> <u>Matériel utilisée</u>	23
<u>3.3.</u> <u>Jeu de données</u>	23
<u>3.4.</u> <u>Etape d'implémentation des expériences de simulation</u>	27
<u>3.5.</u> <u>ésultat et discussion</u>	27
<u>3.6.</u> <u>Conclusion</u>	37

3.1. Introduction

Ce chapitre est consacré à la présentation de nos résultats de simulation, mettant en évidence l'intérêt de l'utilisation des réseaux de deep learning en super résolution. Nous avons réalisé plusieurs expériences pour démontrer les avantages de ces réseaux. Pour chaque expérience menée, nous avons commencé par générer des images basse résolution (LR - Low Resolution). Dans notre étude, nous avons utilisé des facteurs de sous-échantillonnage spécifiques. Ensuite, nous avons implémenté les réseaux de deep Learning, à savoir VDSR et CAR, pour les cas de l'image unique et de l'image multiple, en utilisant des images de test provenant de différentes bases de données. Nous avons réalisé une étude comparative quantitative et qualitative pour chaque image de test, en évaluant les indicateurs PSNR et SSIM, ainsi que la qualité visuelle des images obtenues

3.2. Matériel utilisée

Les sources de code ont été développées et exécutées en Python 3.9.13 en utilisant Spyder Navigator sur un pc hp avec un processeur i5-7300 vPro fonctionnant sous Windows 10 Professional. Les principaux paquets de programmation utilisés en Python étaient PyTorch, qui est spécifiquement conçu pour les implémentations de deep learning. Pour tenir compte des grands ensembles de données, les sources de code primaires ont été exécutées sur Google Colab et MATLAB 2022B. notons que les calculs des critères sont effectués sous Matlab.

3.3. Jeu de données

Nous avons utilisé plusieurs ensembles de données lors de nos expériences de simulation, y compris le LIVE1, qui contient 29 images, et le DIV2K, qui est largement utilisé et contient 1000 images de haute qualité. Nous avons utilisé 800 images pour l'entraînement, 100 images pour la validation et 100 images supplémentaires pour les tests dans l'ensemble de données DIV2K. Nous avons également utilisé Set5 et Set14 et des images bruitées et des images floues pour évaluer nos méthodes

Les tableaux suivants résument l'ensemble de données utilisées

Tableau 3. 1 : Base de données LIVE1

Nom du fichier image	Taille
Bikes	768×512
Builing2	640×512
Building	768×512
Caps	768×512
Carnivaldolls	610×488
Cemetry	627×482
churhancapitol	634×505
coinsinfountain	640×512
dancers	618×453
Flowersonih35	640×512
house	768×512
lighthouse2	768×512
Lighthouse3	480×720
manfishing	634×438
monarch	768×512
ocean	768×512
Paintedhouse	768×512
parrots	768×512
palne	768×512
rapids	768×512
Sailing1	768×512
Sailing2	480×720
Sailing3	480×720
Sailing4	768×512
statue	480×720
stream	768×512
studentsculpture	632×505
Woman	480×720
womanhat	480×720

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Tableau 3. 2 : Base de données set 5

Nom du fichier image	Taille
Baby_G	512×512
Bird_GT	288×288
Butterfly_GT	256×256
Head_GT	280×280
Woman_GT	228×344

Tableau 3. 3 : Base de données set 14

Nom du image	Taille
Baboon	500×480
barbara	720×576
Bridge	512×512
coastguard	352×288
Comic	250×361
Face	276×276
flowers	500×362
foreman	352×288
Lenna	512×512
Man	512×512
monarch	768×512
pepper	512×512
Ppt3	529×656
Zebra	586×391

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

La figure 3.1 illustre les images test de différentes bases de données



Live 1



SET5



SET14

Figure 3. 1 : images originales haut résolution (HR)

Tableau 3. 4 : Base de données images bruitées

Nom du fichier image	format	Base
Noisy1	PNG	RVB
Noisy2	PNG	RVB

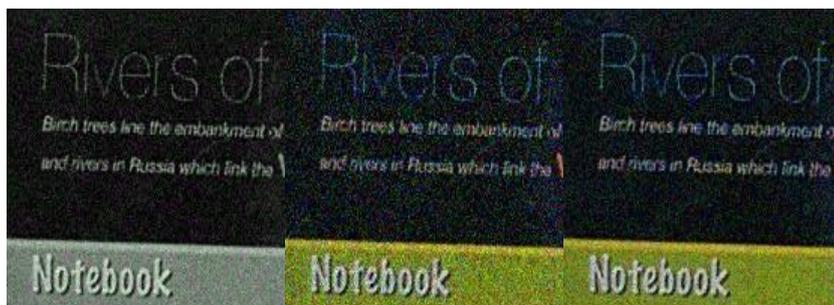


Figure 3. 2 : images bruitées, bruit gaussien additif, $\sigma = 15$

Tableau 3. 5 : Base de données images fusionnées

Nom du fichier image	Taille
firstimage	186×161
Fused	186×161
Second	186×161

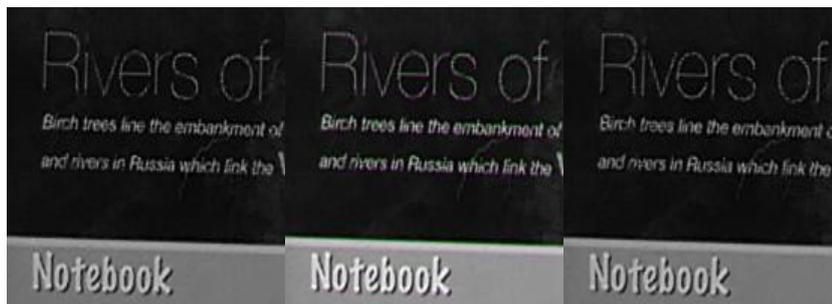


Figure 3. 3 : images fusionnées, avant génération du bruit

3.4. Etape d'implémentation des expériences de simulation

3.4.1. VDSR

Est un algorithme basé sur l'apprentissage en profondeur utilisé pour la super-résolution. Nous avons appliqué ce réseau pour améliorer la qualité des images. Nous considérons que les images originales sont la version haute résolution (HR), donc nous générons d'abord la version low résolution par : (a) sous échantillonnage avec deux valeurs du facteur échelle (x2, x4), (b) génération des copies bruitées en ajoutant un bruit gaussien de différents niveaux.

3.4.2. CAR

Le deuxième réseau DL que nous avons testé est CAR qui est une version amélioré. Rappelons que CAR est une technique utilisée pour redimensionner les images tout en préservant le contenu important et en minimisant les distorsions.

3.5. résultats et discussions

3.5.1. le cas de **single images (SSIR)** : est résumé dans cet organigramme

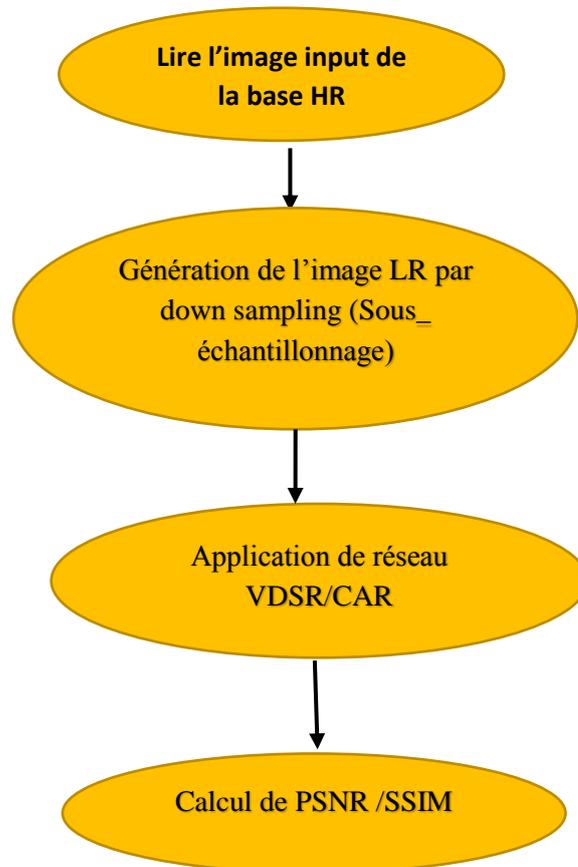


Figure 3. 4 : Etapes d'implémentation de VDSR

3.5.1.1. VDSR

Les étapes d'implémentation de VDSR sont résumées dans l'organigramme de la figure 3.4. Nous générons d'abord les images LR à partir des images HR par simple sous échantillonnage (downsampling). Le cas des images affectées par un bruit gaussien additif est aussi traité dans notre travail, comme nous le verrons par la suite. Après la détérioration d'image, nous appliquons le réseau VDSR pour obtenir l'image super résolution. Pour chaque image des bases de données, nous calculons le PSNR et le SSIM. Nous calculons ensuite leurs valeurs moyennes.

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Tableau de chaque image

- **Cas une seule copie bruitée**

Tableau 3. 6 : les résultats de PSNR et SSIM de la copie bruitée Noisy1

Nom du fichier image	PSNR	SSIM
Noisy1	26.3852	0.9253

Les Tableaux suivants indiquent les valeurs de PSNR et SSIM de chaque image des différentes bases.

Tableau 3. 7 : les résultats de PSNR et SSIM de set 5

Nom du fichier image	PSNR	SSIM
Baby	34.1260	0.9507
Head	30.8626	0.8655
Woman	29.0166	0.9493
Bird	32.7144	0.9654
Butterfly	24.8020	0.8860

- **Jeu de données (set14)**

Tableau 3. 8 : les résultats de PSNR et SSIM de set 14

Nom du fichier image	PSNR	SSIM
Baboon	24.8747	0.8738
Barbara	26.6774	0.8955
Bridge	26.9054	0.8964
Coastguard	26.1873	0.8419
Comic	24.7195	0.9142
Face	30.8345	0.8654
Flowers	27.9459	0.9080
Forman	29.6428	0.9342

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Lenna	30.7330	0.8548
Man	27.9153	0.8850
Monarch	29.9424	0.8857
Pepper	31.0607	0.8659
ppt3	28.1486	0.9561
Zebra	26.0358	0.8511

- **Jeu de données (Live1)**

Tableau 3. 9 : les résultats de PSNR et SSIM de live1

Nom du fichier image	PSNR	SSIM
bikes	24.9793	0.8864
Building2	23.3304	0.8949
Buildings	23.7646	0.8659
Caps	30.3052	0.8681
Carnivaldolls	27.5291	0.9221
Cemetry	25.0510	0.8350
Churchandcapitol	25.5059	0.8952
Coinsinfountain	27.3303	0.8912
Dancers	24.7154	0.8892
Flowersonih35	23.7319	0.9160
House	28.5949	0.8280
Lighthouse2	27.4929	0.8260
Lighthouse3	26.1193	0.8283
Manfishing	26.0046	0.8929
Monarch	29.9424	0.8857
Ocean	29.5872	0.8573
Paintedhouse	26.8352	0.8916
parrots	31.7896	0.8495
Plane	30.1360	0.9061
Rapids	27.4893	0.8725
Sailing1	26.6734	0.8463

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Sailing2	29.8278	0.8195
Sailing3	30.1566	0.8487
Sailing4	27.9960	0.8682
Statue	30.2988	0.9006
Stream	25.1169	0.8863
Studentsculpture	24.4755	0.8805
woman	27.5284	0.8911
Womanhat	31.0906	0.8559

Les valeurs moyennes PSNR et SSIM sont indiqués sur les Tableaux suivants.

Tableau 3. 10 : les résultats moyens de PSNR et SSIM de set 5

MEAN PSNR : 30.3043
MEAN SSIM : 0.9233

Tableau 3. 11 : les résultats moyens de PSNR et SSIM de set 14

MEAN PSNR : 27.9730
MEAN SSIM : 0.8877

Tableau 3. 12 : les résultats moyens de PSNR et SSIM de live1

MEAN PSNR : 27.3585
MEAN SSIM : 0.8723

3.5.1.2. CAR

- **Cas une seule copie bruitée**

Tableau 3. 13 : les résultats de PSNR et SSIM de Noisy1

scale	X2		X4	
	PSN	SSI	PSN	SSI
	R	M	R	M
Nois	25.7	0.61	23.9	0.4
y1	809	87	974	535

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

- **Jeu de données (set5 X2 X4)**

Tableau 3. 14 : les résultats de PSNR et SSIM de set 5

scale	X2		X4	
	PS NR	SSI M	PS NR	SS IM
butte	36.	0.98	30.	0.9
rflly	85		95	4
Head	36.	0.89	33.	0.8
	27		79	2
Wom	37.	0.97	32.	0.9
an	50		84	4
Baby	39.	0.97	35.	0.9
	64		27	2
Bird	44.	0.99	37.	0.9
	51		96	6

- **Jeu de données (set 14 X2 X4)**

Tableau 3. 15 : les résultats de PSNR et SSIM de set 14

Scale	X2		X4	
	PSNR	SSIM	PSNR	SSIM
Flowers	36.74	0.96	30.33	0.86
Coastguard	35.34	0.94	29.30	0.77
Bridge	30.34	0.88	26.39	0.69
Zebra	35.94	0.95	30.61	0.85
Foreman	40.05	0.97	35.85	0.94
Pepper	38.03	0.92	35.43	0.89
Lenna	38.29	0.94	34.22	0.88
Face	36.30	0.89	33.78	0.82
Ppt3	40.08	0.99	30.70	0.97

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Barbara	36.67	0.96	27.94	0.84
Monarch	41.34	0.98	35.47	0.95
Comic	31.88	0.96	25.51	0.82
Baboon	27.95	0.84	24.38	0.65
Man	32.80	0.91	28.53	0.79

- **Jeu de données (Live 1 X2 X4)**

Tableau 3. 16 : les résultats de PSNR et SSIM de live1

scale	X2		X4	
	PSNR	SSIM	PSNR	SSIM
Caps	40.96	0.97	35.45	0.91
manfishing	36.07	0.96	29.91	0.85
Sailing	33.55	0.93	28.38	0.79
carnivaldolls	36.44	0.97	30.42	0.88
coinsinfountain	35.09	0.94	29.92	0.83
Rapids	34.91	0.93	29.70	0.80
Ocean	37.02	0.94	32.04	0.84
churchandcapitol	34.23	0.95	28.29	0.86
Woman	31.95	0.92	28.01	0.79
womanhat	37.43	0.94	33.34	0.86
buildings	32.65	0.94	26.11	0.81
Statue	36.99	0.96	32.31	0.89
Sailing3	39.43	0.96	33.98	0.91
Building2	28.75	0.91	23.67	0.73
Plan	37.90	0.95	33.19	0.90
Bikes	34.52	0.95	27.75	0.82
Sailing4	35.18	0.94	30.45	0.83
Stream	27.89	0.85	23.97	0.64
Dancers	31.02	0.94	25.90	0.83
Lighthouse3	35.76	0.93	30.47	0.84
Cemetry	32.92	0.93	27.43	0.78

Chapitre 3 : Implémentation des algorithmes de super résolution à copie unique (SISR) et à copies multiples (MISR) à base d'apprentissage profond

Parrots	41.75	0.97	35.73	0.94
House	35.76	0.93	31.52	0.83
Flowersonih35	27.70	0.92	23.06	0.75
studentsculpture	30.22	0.92	25.01	0.73
Monarch	41.34	0.98	35.47	0.95
Lighthous2	33.69	0.94	28.95	0.84
Sailing2	38.87	0.96	33.57	0.91
Paintedhouse	31.87	0.94	27.56	0.83

Tableau 3. 17 : les résultats moyens de PSNR et SSIM de set 5

X2	X4
MEAN PSNR : 38.96	MEAN PSNR : 34.17
MEAN SSIM : 0.96	MEAN SSIM : 0.91

Tableau 3. 18 : les résultats moyens de PSNR et SSIM de set14

X2	X4
MEAN PSNR : 35.84	MEAN PSNR : 30.61
MEAN SSIM : 0.93	MEAN SSIM : 0.84

Tableau 3. 19 : les résultats moyens de PSNR et SSIM de Live 1

X2	X4
MEAN PSNR : 34.90	MEAN PSNR : 29.71
MEAN SSIM : 0.94	MEAN SSIM : 0.83

3.5.2. Cas de multi images (MISR)

Nous avons généré des versions bruitées d'une même image, nous avons d'abord effectué la fusion des copies pour obtenir une version fusionnée, puis nous avons appliqué VDSR sur cette version. Les résultats sont résumés sur le Tableau 3.20

3.5.2.1. VDSR

- **Cas d'image bruitée**

Tableau 3. 20 : les résultats de PSNR et SSIM de Noisy_fused

Nom du fichier image	PSNR	SSIM
-----------------------------	-------------	-------------

Noisy_fused	26.2964	0.9096
--------------------	----------------	---------------

Jeu de données (fusionnées)

Tableau 3. 21 : les résultats de PSNR et SSIM des images fusionnées

Nom du fichier image	PSNR	SSIM
Fused	25.6468	0.9104
Firstimage	26.8041	0.9152
Second	26.7617	0.9162

L'image fusionnée est obtenue par la règle de fusion mean. Cette image est l'input du réseau VDSR.

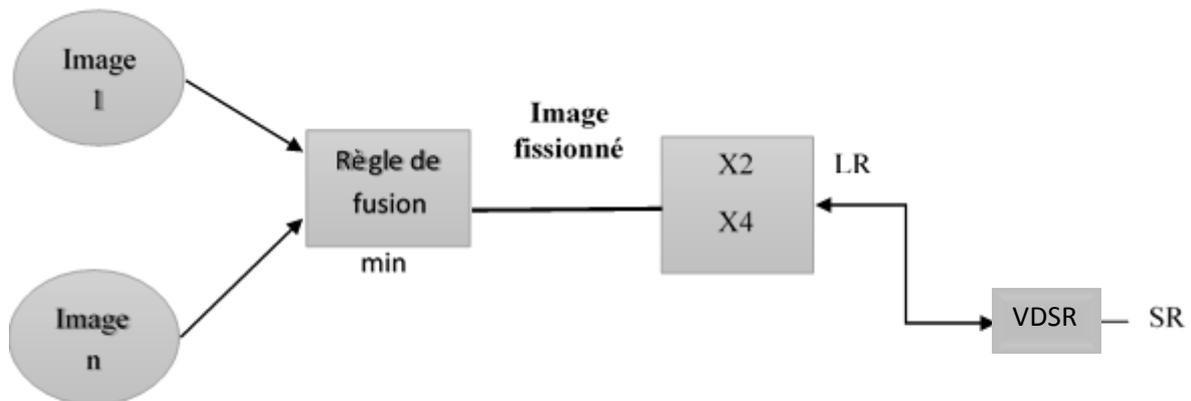


Figure 3. 5 : Schéma de VDSR dans le cas MISR

3.5.2.2. CAR

Nous appliquons dans cette section le schéma de fusion mean suivi du réseau CAR ; d'abord les images sont nettes, comme c'est résumé sur la Figure 3.6. L'image fusionnée est obtenue par la règle de fusion mean. Cette image est l'input du réseau CAR.

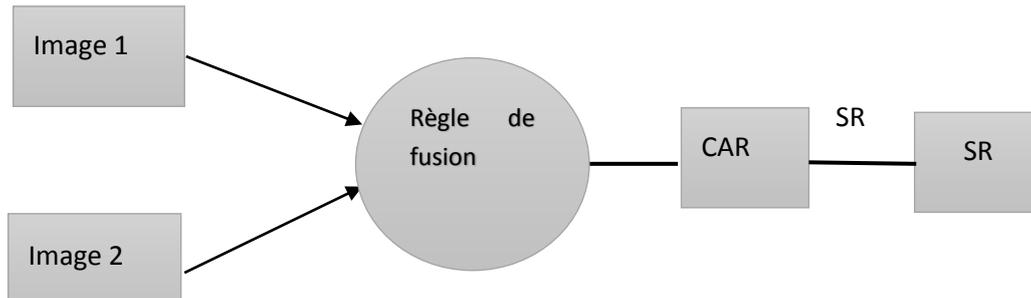


Figure 3. 6 : Schémas de CAR

- **Cas d'image bruitée**

Dans cette expérience, nous générons les version bruitées de l'image originale, dans ce cas, nous avons deux dégradations : le bruit. L'image fusionnée est l'entrée du réseau CAR ; la deuxième dégradation qui est le sous échantillonnage est introduite par le réseau CAR. Les résultats de PSNR et SSIM sont résumés sur le Tableau 3.24.

Tableau 3. 22 : les résultats de PSNR et SSIM des images fusionnées

Scale	X2		X4	
	PSNR	SSIM	PSNR	SSIM
Fusedimage	38.13	0.98	30.26	0.91
Firstimage	36.26	0.97	28.10	0.89
Fused	35.73	0.97	27.34	0.89

3.6. Conclusion

Nous avons exposé dans cette partie tous les résultats de simulation que nous avons obtenus. Nous avons d'abord implémenté les deux réseaux VDSR et CAR sur une seule image. Nous avons considéré une seule dégradation qui est le sous échantillonnage ; pour VDSR nous générons d'abord les images LR ; pour CAR l'entrée est laissée HR, parce que la génération des images LR est incluse dans le réseau. Nous avons testé les deux réseaux DL pour les images à une seule copie. Les images sont prises des datasets usuelles de ce domaine. Nous avons ensuite pris le cas MISR, nous avons concaténé un bloc de fusion en amont du réseau DL. Une appréciation qualitative et quantitative en terme de PSNR et SSIM a été effectuée. Pour conclure, la règle de fusion mean et le faible nombre de copies, n'ont pas permis une amélioration considérable des images SR. Il faut disposer d'une règle de fusion efficace, appliquée sur un grand nombre de copies d'une seule image pour assurer une bonne qualité de l'image fusionnée.

Conclusion Générale

Notre objectif de ce travail a consisté à reconstruire des images haute résolution (HR) à partir d'images basse résolution (LR) en utilisant des algorithmes d'apprentissage profond. Nous avons utilisé les premier réseau VDSR, ainsi que le réseau CAR. Nous avons discuté le cas d'images d'une seule copie (SISR) et à multicopies bruitées (MISR). Nous avons calculé PSNR et SSIM pour chaque images des différente bases. Nous avons introduit les concepts de base de la super résolution d'images dans le premier chapitre. Nous avons mis l'accent sur deux réseaux DL appliqués en super résolution, VDSR et CAR. Nous avons déterminé la terminologie du domaine deep learning dans le deuxième chapitre. Nous avons exposé nos résultats dans le troisième chapitre.

D'après les résultats obtenus, nous avons remarqué que :

- Les deux réseaux DL VDSR et CAR ont permis une qualité visuelle améliorée de l'image résultante.
- VDSR et CAR sont robustes par rapport au bruit additif gaussien
- Il faut utiliser un grand nombre de copies d'une même image dans le cas MISR, pour obtenir des résultats satisfaisants
- Il faut choisir une règle de fusion adéquate pour créer une version HR à l'entrée du réseau CAR

Bibliographie

- [1] w. saadallah 'Apprentissage Profond Pour La Super Résolution Des Images', mémoire de master, publié 2022.
- [2] Farsiu, S.; Robison, M.D.; Elad, M.; Milanfar, P., "Fast and robust multiframe super resolution," *Image Processing, IEEE Transactions on*, vol.13, no.10, pp.1327,1344, Oct. 2004, doi: 10.1109/TIP.2004.834669
- [3] S. Borman and R. Stevenson, *Spatial Resolution Enhancement of Low-Resolution Image Sequences – A Comprehensive Review with Directions for Future Research*, Technical report, University of Notre Dame, 1998
- [4] M. Bertero and P. Boccacci. "Super-resolution in computational imaging". *Micron*, 34:265–273, October 2003.
- [5] A. Singh, A. Kaur, N. Kaur, and H. Saini, "Image Enhancement Techniques: A Comprehensive Survey," *IEEE Access*, vol. 6, pp. 52080-52109, 2018.
- [6] Dong, C., Loy, C. C., He, K., Tang, X., 'Image Super-Resolution Using Deep Convolutional Networks', *Journal*, publié 01 June 2015
- [7] S.Sid Ahmed, Z. Messali, A. Ouahabi, S. Trepout, C. Messaoudi, S. Marco, 'Nonparametric Denoising Methods Based on Contourlet Transform with Sharp Frequency Localization: Application to Low Exposure Time Electron Microscopy Images'. *article*; publié 24 may 2015.
- [8] R. C. Gonzalez, R.E. Woods 'Digital Image Processing', *book*, 2008
- [9] Liangliang. Li, Ming. Lv, Zhenhong. Jia, Hongbing. Ma, 'Sparse Representation-Based Multi-Focus Image Fusion Method via Local Energy in Shearlet Domain', *article*, publié 7 march 2023
- [10] Keys, R.G. "Cubic Convolution Interpolation for Digital Image Processing.", *Journal*, Publié: *IEEE Transactions on Acoustics, Speech, and Signal Processing* (Volume: 29, Issue: 6, December 1981)
- [11] Sun, J. Jia, C.-K. Tang, *Image*, "Super-Resolution Using Bilinear Interpolation-Based Discrete Cosine Transform ", *article*, publié vol. 10, no. 2, pp. 291-300, Feb.2008.
- [12] Chao Dong, Chen Change Loy, Kaiming He, Xiaoou Tang, "Image Super-Resolution Using Deep Convolutional Networks", *Year*: 31 Jul 2015
- [13] Dong, C., Loy, C. C., He, K., & Tang, X. (2016). 'Image super-resolution using deep convolutional networks', *journal*, Published in: *IEEE Transactions on Pattern Analysis and Machine Intelligence* (Volume: 38, Issue: 2, 01 February 2016).
- [14] Jiwon Kim, Jung Kwon Lee and Kyoung Mu Lee, "Accurate Image Super-Resolution Using Very Deep Convolutional Networks», *article*, publié au CVPR en 2016
- [15] M. Taghizadeh and S. V. Voronin, "Content-Adaptive Resampling for Image Super-Resolution", *by* 2015
- [16] Wanjie Sun, Zhenzhong Chen, "Learned Image Downscaling for Upscaling using Content Adaptive Resampler ", *publié* le Jul 22, 2019.
- [17] A. Bengueddoudj, Z. Messali, ' An Efficient Algorithm for Multimodal Medical Image Fusion based on Feature Selection and PCA Using DTCWT (FSPCA-DTCWT)', *MTJ journal*, Vol. 2, N°1, (2018) January-March 2018
- [18] [Zhou Wang, , Alan Conrad Bovik, , Hamid Rahim Sheikh, and Eero P. Simoncelli, Senior, 'Image Quality Assessment: From Error Visibility to Structural Similarity', *IEEE TRANSACTIONS ON IMAGE PROCESSING*, VOL. 13, NO. 4, APRIL 2004]

- [19] [Zhou Wang, , Alan Conrad Bovik, , Hamid Rahim Sheikh, and Eero P. Simoncelli, Senior, 'Image Quality Assessment: From Error Visibility to Structural Similarit', IEEE TRANSACTIONS ON IMAGE PROCESSING, VOL. 13, NO. 4, APRIL 2004]
- [20] M.Boughaba, B. Boukhris ' L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu ', mémoire master année 2016/2017.
- [21] Oracle Algeria, ' Intelligence artificielle (Services de machine Learning). [Site web] <https://www.oracle.com/dz/artificial-intelligence/> , (pas de date).
- [22] D.Peterson, TechTarget (What is supervised learning?). [Site web], (2021a)
- [23] M.Boughaba, B. Boukhris ' L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu ', mémoire master année 2016/2017. Page 13
- [24] T. rédac, datascientest (Qu'est-ce qu'un dataset ?). [Site web], (2023).
- [25] L. Gayhardt, learn. Microsoft (Deep learning vs. machine learning in Azure Machine Learning). Article (mars 2023).
- [26] J. Jasmin, natural-solutions (LES RÉSEAUX DE NEURONES CONVOLUTIFS). [Site web], APRIL 17, 2018.
- [27] M. RAMDANE & M. DJARER ' contrôle intelligent par réseaux de neurone pour la détection d'anomalie en radiothérapie ', mémoire master année 2018/2019. Page 16-17.
- [28] Hubel DH, Wiesel TN (1968) Receptive fields and functional architecture of monkey striate cortex. J Physiol 195:215–243
- [29] P. Sharma, (2020). A Comprehensive Tutorial to learn Convolutional Neural
- [30] Lijo Jacob,Varghese Suma, Sira Jacob, Sundar Chinnasamy ,Jacob Raglend I,"Design and Implementation of a Machine Learning Assisted Smart Wheelchair in an IoT Environment",publié May 2021
- [31] Savyakhosla, GeeksforGeeks "CNN: Introduction to pooling layer." article, (pas de date)
- [32] I. Arshad, Pooling layer: Towards understanding the building blocks of Convolutions Neural Networks, article, publié 11mars 2023
- [33] N. Belaidi, Data Scientist (Réseaux convolutifs (CNN) : comment ça marche ?). Article, Publié le 21 juin 2022
- [34] Charlotte Pelletier, Geoffrey I Webb, François Petitjean, "Temporal Convolutional Neural Network for the Classification of Satellite Image Time Séries ", article, publié Mar 2019