

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF – M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT D'ELECTRONIQUE
N° :



DOMAINE : SCIENCES ET TECHNOLOGIE
FILIERE : ELECTRONIQUE
OPTION : ELECTRONIQUE DES SYSTEMES
EMARQUEES

Mémoire présenté pour l'obtention
Du diplôme de Master Académique
Intitulé

Une méthode de segmentation d'images médicales
Basée sur des caractéristiques statistiques

Présenté Par :

BOUBAYA BOUCHRA
SMAILI FATIMA

Soutenu devant le jury composé de :

Dr BENAHCENE Madani	Université de M'SILA	Président
Dr LAHOUAOUI Lalaoui	Université de M'SILA	Encadreur
Dr ZERDOUMI Zohra	Université de M'SILA	Examinatrice

Année universitaire : 2023 /2024

Remerciement

En premier lieu, nous remercions ALLAH, le tout puissant et miséricordieux, qui nous a donné la force le courage et la patience d'accomplir ce modeste travail.

Nos remerciements et nos profondes gratitudes vont à notre Encadreur Monsieur “Lahouaoui Lalaoui” ses précieux conseils et pour tout le soutien et l'orientation. D'avoir bien voulu diriger notre travail, et d'avoir donné le meilleur de son savoir et de son aide, et surtout d'avoir fait preuve de beaucoup de patience, son aide durant toute la période du travail.

Nous tenons aussi à remercier les membres du jury pour leur précieux temps accordé à l'étude de notre mémoire.

Nous remercions nos enseignants pour leurs efforts, nos parents et nos proches pour l'amour et le soutien constant qu'ils nous ont témoigné tout au long de notre parcours. Merci à toutes et tous nos ami(e)s pour leurs encouragements.

DEDICACES

Je dédie cet humble travail

A mes chers parents, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études ,

A celle qui m'a donné la vie, la source de la tendresse, ma chère mère Lkamla qui m'a apporté son appui durant toute mes années d'étude, pour son sacrifice et soutien qui m'ont donné l'amour, le courage et la sécurité ;

A mon cher père Abderrazak qui m'a entouré de tous ses encouragements et son aide durant toute la période de mes études.

A mes chères sœurs: Sarra ,Ahlam,Loubna,Aya et Meryam pour leurs encouragements permanents, et leur soutien moral ,

A mon cher frère, Mohamed

A Mes neveux, Mohamad ,Riham et Youssef

A toute la famille Boubaya

A tous mes amis et tous les étudiants de la spécialité électronique des systèmes embarqués promotion (2024)

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

BOUBAYA BOUCHRA

DEDICACES

Je dédie cet humble travail

A la source de générosité qui m'a inculqué l'ambition et la persévérance .

...Mon cher père...

*A la source de tendresse qui m'a donné la vie et qui m'a soutenu tout au long de mes années
d'études .*

...ma chère mère...

A la source de ma force, de ma côte stable et de ma sécurité, à l'inspiration de mon succès .

...Mon frère et mes sœurs...

A la première petite-fille de la famille .

...Heba Al-Rahman...

A toute la famille SMAILI .

A mes amies .

*A toutes les personnes qui me reconnaissent et qui mon aide et contribue à la réalisation de
ce travail .*

SMAILI FATIMA

Table des matières

Introduction générale	8
CHAPITRE I	10
Les Méthodes de segmentation d'images	10
<i>I.1 Introduction</i>	11
<i>I.2 Définition de la segmentation</i>	11
<i>I.3 Objectifs de la segmentation</i>	12
<i>I.4 Les différentes étapes pour segmenter les images</i>	12
<i>I.5 Domaines d'application de la segmentation d'image</i>	13
✓ Imagerie médicale	13
✓ Analyse d'images satellitaires	14
✓ Véhicules autonomes	14
<i>I.6 Choix d'une méthode de segmentation</i>	14
<i>I.7 Différentes approches de segmentation</i>	14
<i>I.7.1 Segmentation Basée sur la Région</i>	15
I.7.1.1 Segmentation par Croissance de Région	15
I.7.1.2 Segmentation par Fusion de Régions (Merge)	17
I.7.1.3 Segmentation par Division de Régions (Split)	17
I.7.1.4 Segmentation par division-fusion (Split and Merge)	18
<i>I.7.2 Segmentation Basée sur contours</i>	18
<i>I.7.3 Segmentation Basée sur classification</i>	22
I.8 Conclusion	23
CHAPITRE II	25
Deep Learning	25
<i>II.1 Introduction</i>	26
<i>II.2 Définition de l'apprentissage profond (Deep Learning)</i>	27
Pourquoi le deep Learning ?	27
<i>II.3 Fonctionne du Deep Learning</i>	29
<i>II.4 Les architectures de Deep Learning</i>	30
<i>II.5 Introduction sur Réseaux de neurones</i>	30
<i>II.6 Les réseaux de neurones convolutifs</i>	32
<i>II.7 Les principaux composants du CNN</i>	33
II.7.1. Les couches de CNN	34
<i>II.8 Architecture de CNN</i>	37
II.8.1. Architecture U-Net	38

<i>II.9 Avantages d'un CNN dans le domaine de la reconnaissance d'images</i>	40
<i>II.10 Paramètres de CNN</i>	40
II.11. Conclusion	40
CHAPITRE III	42
Résultats	42
<i>III.1 Introductions</i>	43
<i>III.2 la base de données utilisée</i>	43
<i>III .3 Logiciel d'utilisée</i>	44
III .3 .1 Python	44
III .3.2 Google Colab	44
<i>III. 4 Méthodologie</i>	45
<i>III.5 Dataset Description</i>	46
<i>III.6 Segmentation Résultats</i>	47
<i>III.7 Prétraitement des données</i>	48
<i>III.8 Train - Test Divisé</i>	49
<i>III.9 Modèle d'apprentissage automatique</i>	49
<i>III.10 Entraînement du modèle</i>	50
<i>III.11 Évaluation des performances</i>	50
<i>III.12 Métrique de qualité d'image</i>	51
<i>III.13 Afficher les résultats</i>	53
III.14 Conclusion	54
Conclusion Générale	56

List des figures

Figure I.1 : Exemple de segmentation d'image.....	09
Figure I.2 : Etapes de segmentation d'images.....	11
Figure I.3 : Principales méthodes de segmentation.....	13
Figure I.4 : Croissance progressive d'une région.....	14
Figure I.5 : Résultat final de la croissance de régions.....	14
Figure I.6 : Exemple de segmentation par division de régions.....	15
Figure I.7 : Agrégation itérative des blocs similaires au bloc l.....	16
Figure I.8 : quelques modèles de contours.....	17
Figure I.9 : contour et ses dérivées.....	17
Figure I.10 : Détection de contour par les différents filtres.....	18
Figure I.11 : image originale (à gauche), contour détecté par Laplacien.....	19
Figure I.12 Exemple d'application du filtre de CANNY.....	19
Figure I.13 (a) Le contour initial et (b) le contour à l'état de convergence.....	20
Figure II.1 : Artificial Intelligence Vs Machine Learning Vs Deep Learning.....	25
Figure II.2 : Le graphe entre Deep learning vs Machine learning.....	26
Figure II.3 : Différence entre Deep learning et Machine learning.....	27
Figure II.4 : Exemple de réseau de neurones.....	29
Figure II.5 : Convolution Neural Network.....	31
Figure II.6 : Les principaux composants du CNN.....	32
Figure II.7 : Schéma du parcours de la fenêtre de filtre sur l'image.....	33
Figure II.8 : la couche de Pooling.....	33
Figure II.9 : Processus de Max-Pooling.....	34
Figure II.10 : Fonction d'activation Relu.....	34
Figure II.11 : Fully-connected Layer.....	35
Figure II.12 : Architecture d'un réseau de neurones CNN.....	36
Figure II.13 : Architecture U-Net.....	37
Figure III.1 : Répartition du nombre d'images et de masques pour chaque catégorie.....	45
Figure III.2 : Représentation visuelle de chaque classe.....	46
Figure III.3 : U-Net Convolutional Networks.....	47
Figure III.4 : Visualisation de l'apprentissage.....	48
Figure III.5 : Perte et Précision.....	48
Figure III.6 : Résultats de prédiction du modèle dans les images médicales.....	51

Résumé

Cette étude se concentre sur le développement de techniques de segmentation des images médicales en utilisant des caractéristiques statistiques afin d'améliorer la précision de l'analyse des images dans les applications cliniques. La segmentation des images médicales est essentielle pour le diagnostic, la planification thérapeutique et la surveillance des maladies, car elle consiste à diviser l'image en parties distinctes pour faciliter leur analyse.

L'étude met en avant l'utilisation de caractéristiques statistiques telles que la moyenne, la variance et l'écart-type pour différencier les différentes zones au sein des images médicales. Elle examine diverses techniques de segmentation, allant des méthodes traditionnelles comme le seuillage aux méthodes avancées telles que l'apprentissage automatique et les réseaux neuronaux profonds, qui offrent une plus grande précision grâce à l'apprentissage à partir de vastes ensembles de données.

Les applications pratiques de ces techniques incluent l'analyse des images pour identifier les tumeurs et évaluer le cancer du sein. L'étude met en lumière les défis liés à la qualité et à la complexité des images, et explore les tendances futures, notamment l'utilisation de l'intelligence artificielle et l'intégration avec d'autres technologies pour améliorer la précision du diagnostic et du traitement.

Les résultats soulignent l'importance de la segmentation des images médicales et son rôle crucial dans l'amélioration des applications cliniques. Ils montrent que l'utilisation des caractéristiques statistiques peut renforcer l'efficacité de la segmentation, contribuant ainsi au développement de solutions médicales plus précises et avancées.

Mots-clés : Segmentation des images médicales, Caractéristiques statistiques, Apprentissage automatique, Réseaux neuronaux, Diagnostic médical, Analyse d'image

Abstract

This study focuses on the development of medical image segmentation techniques using statistical features to improve the accuracy of image analysis in clinical applications. Segmentation of medical images is essential for diagnosis, therapeutic planning and disease surveillance, as it involves dividing the image into separate parts to facilitate their analysis.

The study highlights the use of statistical characteristics such as mean, variance and standard deviation to differentiate different areas within medical images. It examines various segmentation techniques, ranging from traditional methods like thresholding to advanced methods such as machine learning and deep neural networks, that provide greater accuracy through learning from large data sets.

Practical applications of these techniques include image analysis to identify tumors and evaluate breast cancer. The study highlights challenges related to image quality and complexity, and explores future trends, including the use of artificial intelligence and integration with other technologies to improve diagnostic and treatment accuracy.

The results highlight the importance of medical image segmentation and its crucial role in improving clinical applications. They show that the use of statistical characteristics can enhance the effectiveness of segmentation, thus contributing to the development of more precise and advanced medical solutions.

Keywords: Segmentation of medical images, Statistical characteristics, Machine learning, Neural networks, Medical diagnosis, Image analysis

ملخص

تركز هذه الدراسة على تطوير تقنيات تجزئة الصور الطبية باستخدام السمات الإحصائية لتحسين دقة تحليل الصور في التطبيقات السريرية. يعد تجزئة الصور الطبية أمرًا ضروريًا للتشخيص والتخطيط العلاجي ومراقبة الأمراض، حيث يتضمن تقسيم الصورة إلى أجزاء متميزة لتسهيل تحليلها.

تسلط الدراسة الضوء على استخدام الخصائص الإحصائية مثل المتوسط والتباين والانحراف المعياري للتمييز بين المناطق المختلفة داخل الصور الطبية. وتبحث الدراسة في تقنيات التجزئة المختلفة، بدءاً من الأساليب التقليدية مثل تحديد العتبة إلى الأساليب المتقدمة مثل التعلم الآلي والشبكات العصبية العميقة، والتي توفر دقة أكبر من خلال التعلم من مجموعات البيانات الكبيرة.

تشمل التطبيقات العملية لهذه التقنيات تحليل الصور لتحديد الأورام وتقييم سرطان الثدي. تسلط الدراسة الضوء على التحديات المرتبطة بجودة الصورة وتعقيدها، وتستكشف الاتجاهات المستقبلية، بما في ذلك استخدام الذكاء الاصطناعي والتكامل مع التقنيات الأخرى لتحسين دقة التشخيص والعلاج.

تسلط النتائج الضوء على أهمية تجزئة الصور الطبية ودورها الحاسم في تحسين التطبيقات السريرية. وتظهر النتائج أن استخدام السمات الإحصائية يمكن أن يعزز كفاءة التجزئة، وبالتالي المساهمة في تطوير حلول طبية أكثر دقة وتقدماً.

الكلمات المفتاحية: تجزئة الصور الطبية، الميزات الإحصائية، التعلم الآلي، الشبكات العصبية، التشخيص الطبي، تحليل الصور

Introduction générale

Introduction générale

La résonance magnétique pour l'imagerie IRM est l'une des nouvelles méthodes d'imagerie médicale, elle permet de voir avec une grande précision les organes et les tissus mous dans divers plans de l'espace, permettant ainsi de localiser précisément les lésions qui étaient auparavant invisibles.

Les médecins considèrent que l'interprétation des IRM est une étape très délicate pour mettre en évidence les anomalies et donc conclure à un diagnostic correct, en raison des bruits et parasites qui altèrent la qualité de l'image et du manque de précision dans ses différentes substances, les mettant en doute et les contraignant à recourir à d'autres types d'explorations qui s'avèrent pénibles, tant pour les médecins par leur temps d'attente que pour les patients par leurs coût élevé, en tenant compte du risque d'aggraver leurs conditions de santé.

C'est pourquoi les systèmes automatiques de segmentation médicale sont indispensables, une tâche essentielle qui consiste à séparer une image numérique en plusieurs segments, dans le but de simplifier et de transformer sa représentation en quelque chose de plus important et plus facile à analyser par l'homme, afin d'aider le praticien à poser le diagnostic le plus approprié.

Nous visons à fournir une telle assistance, un outil permettant une segmentation rapide, précise et efficace contre les éventuelles altérations des images réalisées par IRM.

Pour atteindre cet objectif, nous avons employé d'une part l'apprentissage profond ou deep learning (DL) en anglais, qui est un type d'intelligence artificielle basé sur l'apprentissage automatique, où la machine est capable d'apprendre par elle-même.

D'où la nécessité des systèmes automatiques de segmentation médicale, une tâche cruciale qui consiste à diviser une image numérique en plusieurs segments dont le but est de simplifier et de changer sa représentation en quelque chose de plus significatif et plus facile à analyser par l'humain, afin d'apporter une aide permettant au praticien de poser le diagnostic le plus adéquat.

Les méthodes de segmentation sont diverses, allant de la segmentation par contours à celle qui se base sur la classification des pixels en fonction de leur intensité, avec l'apparition de méthodes basées sur l'apprentissage automatique telles que les architectures U-Net. La qualité de la segmentation dépend de divers facteurs tels que la nature de l'image, les opérations post-segmentation, les primitives à extraire et les contraintes d'exploitation.

La segmentation d'image médicale est un processus crucial en imagerie biomédicale qui consiste à diviser une image en régions ou catégories distinctes pour faciliter l'analyse. Elle

permet aux médecins d'isoler des structures spécifiques, telles que des organes ou des tumeurs, et est essentielle pour le diagnostic, le suivi et le traitement des patients.

Des techniques avancées comme l'apprentissage profond sont souvent utilisées pour améliorer la précision de la segmentation.

En conclusion, la segmentation d'image médicale est un domaine en constante évolution, offrant de nouvelles perspectives pour le diagnostic assisté par ordinateur et l'analyse fine des structures anatomiques et pathologiques.

Dans notre projet, nous avons utilisé l'apprentissage profond basé sur les réseaux de neurones convolutifs les plus courants pour mettre en œuvre la segmentation d'images à l'aide de la base l'architecture U-Net. Ce travail est organisé en trois chapitres :

- Dans le premier chapitre on va présenter les méthodes de la segmentation d'images.
- Le deuxième chapitre nous vons explique le deep learning et comment utiliser CNN l'architecture U-Net.
- Ce troisième chapitre présente le programme et la méthode utilisés pour segmenter les images et les résultats médicaux pour le cancer du sein.

CHAPITRE I

Les Méthodes de segmentation d'images

I.1 Introduction

L'homme a une capacité naturelle à distinguer des objets dans une image. Afin de distinguer un objet de son environnement, l'être humain utilise des connaissances avancées qui lui permettent de repérer ce qui l'intéresse dans l'image.

La segmentation est une méthode qui implique de diviser une image en zones connexes qui présentent une homogénéité en fonction d'un critère spécifique, comme la couleur par exemple. Le regroupement de ces régions doit rétablir l'image initiale. La segmentation est un élément essentiel pour extraire les données qualitatives de l'image. Elle offre une description de grande qualité. [1]

I.2 Définition de la segmentation

La segmentation représente une étape cruciale dans l'analyse d'images, influençant la qualité des mesures ultérieures. Souvent, elle constitue la première étape d'un processus plus complexe tel que la reconnaissance de formes. Son rôle est de définir les contours des objets à analyser et de délimiter les régions d'intérêt, permettant ainsi de les isoler du fond.

Une méthode de segmentation efficace sera celle qui assure une interprétation précise tout en préservant au mieux le contenu de l'image




Figure I.1 : Exemple de segmentation d'image

À ce jour, il existe des nombreuses méthodes de segmentation qui sont pratiquement toutes sensibles au bruit. Il est donc nécessaire de commencer par nettoyer l'image en appliquant les filtres usuels d'atténuation le bruit. Parmi les approches (la segmentation les plus connues), on peut citer : la segmentation basée sur le seuillage, la segmentation basée sur les régions et la segmentation basée sur les contours. [2]

La segmentation est une décomposition de l'image I en n régions R_i tel que :

1. $\cup_i R_i = I$.
2. $R_i \cap R_j = \emptyset$
3. $P(R_i) = \text{vrai}$.
4. $P(R_i \cap R_j) = \text{faux}$.

En conclusion La segmentation consiste à :

- Regrouper les pixels de l'image qui partagent une même propriété pour former des régions homogènes.
- Répartir l'ensemble de pixels de l'image en différents groupes.
- Découper l'image en région. Une région est caractérisée par contours et par homogénéité (par exemple, même couleur).
- Partitionner une image en un ensemble de régions connexes et disjointes.
- La recherche de zones de l'image possédant des attributs communs, comme la
- Luminosité, la couleur ou plus rarement la texture.

✓ **L'importance de la segmentation**

Une bonne segmentation d'image contribue à une bonne analyse d'image car, à partir de l'image segmentée, des mesures sont prises pour extraire des paramètres discriminants en vue d'une classification ou d'une interprétation. La segmentation d'une image est une étape critique et significative de l'analyse d'une image.

I.3 Objectifs de la segmentation

La segmentation des images sert les objectifs suivants :

- ✓ Fournir des régions homogènes (basées sur un critère spécifié) dans le but d'appliquer un certain traitement et d'interpréter le contenu de l'image.
- ✓ Diminuer le bruit,
- ✓ Extraction de l'information qualitative de l'image, y compris les similitudes (textures, couleurs, intensités, etc.).
- ✓ Déterminer précisément les contours des régions (les arêtes, les transformations abruptes, etc.)

I.4 Les différentes étapes pour segmenter les images

La figure (Figure I.2) résume les différentes étapes nécessaires à la segmentation d'une image.

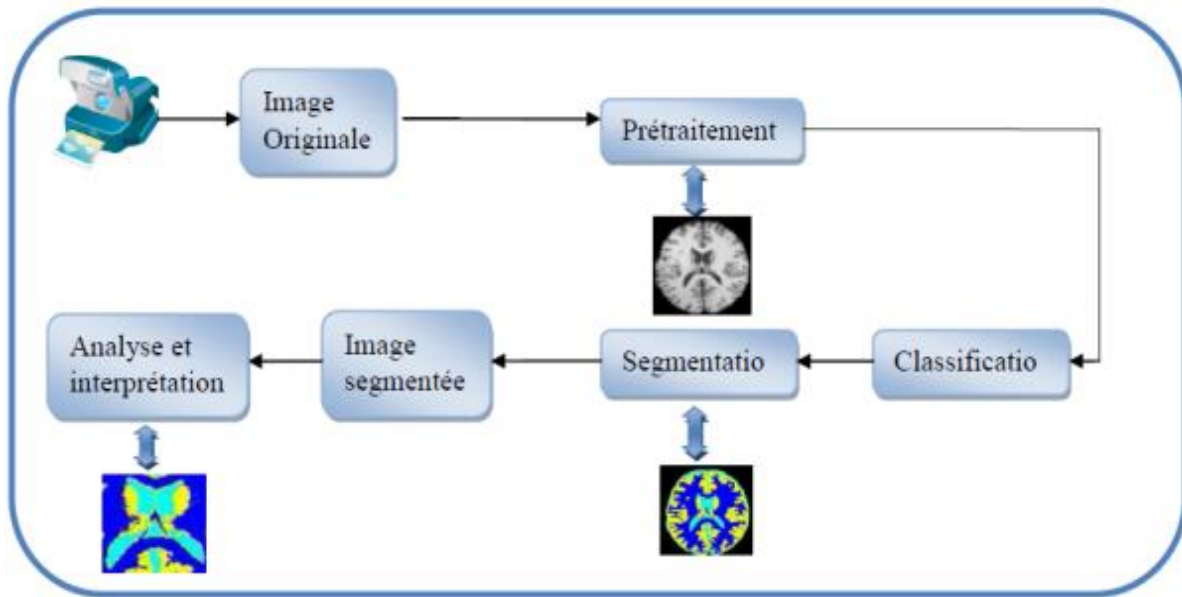


Figure I.2: Etapes de segmentation d'images

✓ Le prétraitement comprend diverses opérations pour améliorer la qualité de l'image et faciliter la segmentation. L'objectif principal de ces opérations est d'améliorer le contraste, de modifier l'histogramme et de réduire le bruit.

✓ Le processus de classification précède le processus de segmentation : comme une image est formée en un certain nombre de classes, le processus de classification équivaut à attribuer chaque pixel de l'image à l'une de ces classes en fonction de critères appropriés.

✓ La segmentation est une technique de traitement de bas niveau qui divise une image en petits groupes appelés régions. Ensuite, la segmentation est obtenue en extrayant les composants connexes de pixels appartenant à la même classe. Ainsi, la région sera composée de pixels de la même classe, mais il peut également y avoir plusieurs régions de l'image qui correspondent à la même classe.

✓ Analyse d'image : extraire des paramètres ou des fonctions représentatives de l'image ou des régions.

L'objectif de l'analyse est d'identifier les paramètres caractéristiques qui permettent de classer les pixels de l'image.

I.5 Domaines d'application de la segmentation d'image

✓ Imagerie médicale

La segmentation d'image est largement utilisée dans la radiographie, l'imagerie par résonance magnétique (IRM), l'échographie et la tomographie par émission de positons (TEP). Elle permet de

découper les images en zones pour compter des cellules, détecter des changements ou des anomalies. [3]

✓ **Analyse d'images satellitaires**

La segmentation d'image est également utilisée pour l'analyse d'images provenant de satellites.

✓ **Véhicules autonomes**

Dans le domaine des véhicules autonomes, la segmentation d'image aide à identifier les objets et à comprendre l'environnement routier. En somme, la segmentation d'image est une méthode polyvalente et pratique qui trouve des applications dans divers domaines, de la médecine à la robotique en passant par l'analyse d'images satellite. [3] [4]

I.6 Choix d'une méthode de segmentation

Une bonne stratégie de segmentation est difficile à définir en termes absolus, et le choix d'une technique est lié à :

- les caractéristiques de l'image (texture, contours, éclairage, etc.)
- Aux opérations de segmentation en cours (compression, reconnaissance de forme, etc.)
- Les primitives supplémentaires (compétences, région, textures, etc.)
- Les contraintes d'exploitation (temps réel, espace mémoire, etc.)

I.7 Différentes approches de segmentation

La segmentation d'images joue un rôle crucial dans le traitement et l'analyse d'images, et elle peut être effectuée de diverses manières en fonction des caractéristiques de l'image et des objectifs de l'analyse.

Voici un aperçu des méthodes de segmentation les plus courantes :

- Segmentation Basée sur la Région (en anglais : régions-based segmentation).
- Segmentation Basée sur les Contours (en anglais : edge-based segmentation).
- Segmentation Basée sur les classifications

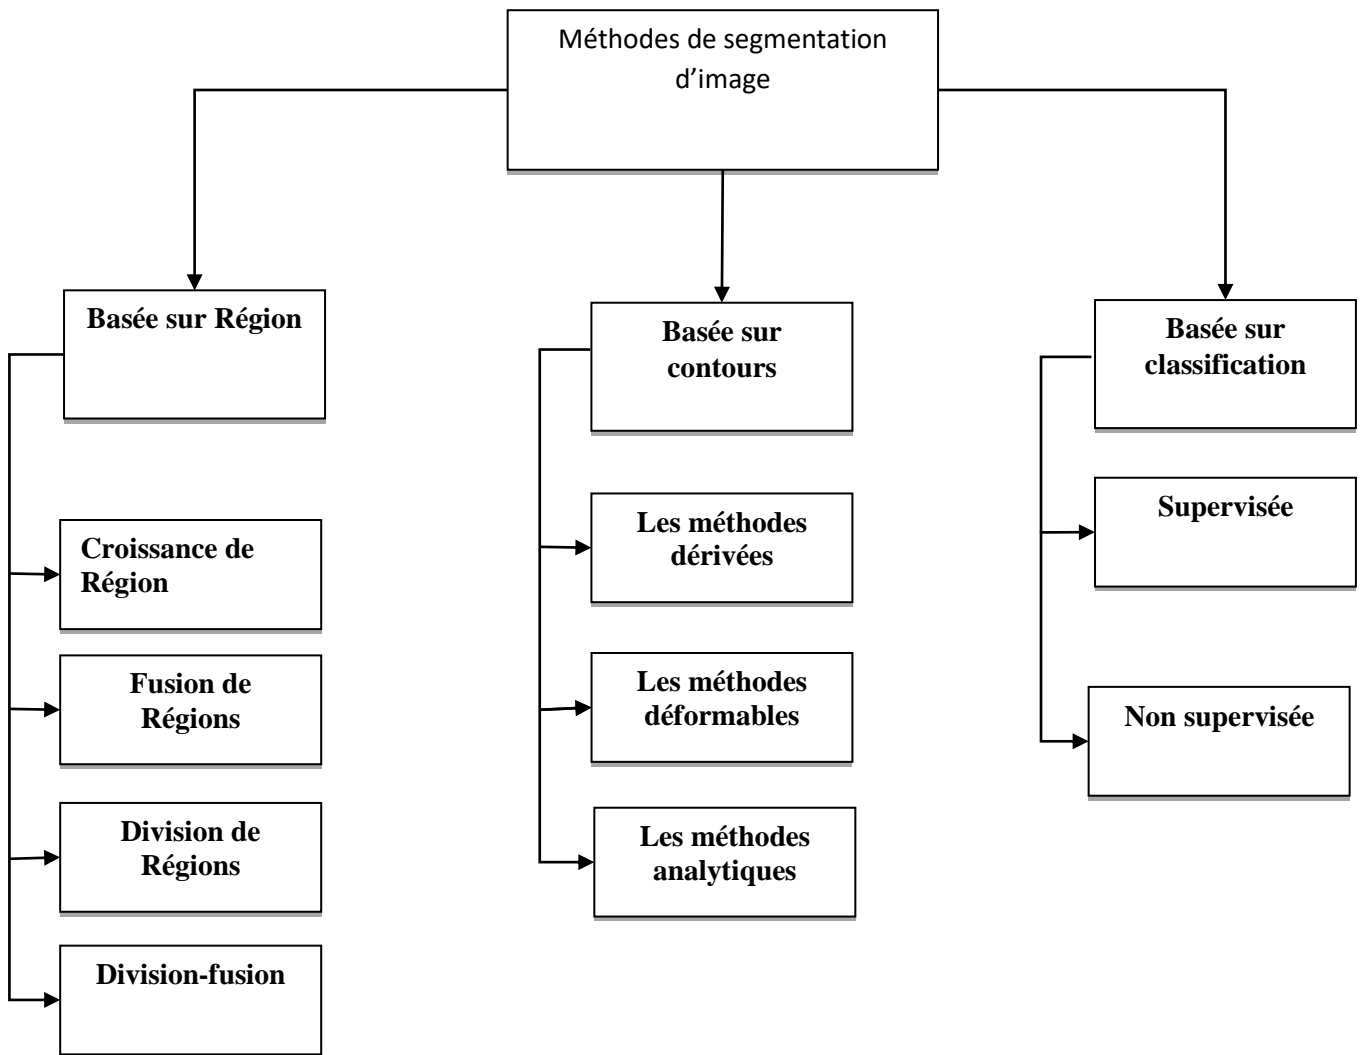


Figure I.3 : Principales méthodes de segmentation.

I.7.1 Segmentation Basée sur la Région

L'objectif des méthodes régionales est de repérer et de mettre en évidence les zones homogènes d'une image. Ces méthodes impliquent la recherche de groupes de pixels qui possèdent des caractéristiques similaires. La distinction entre les régions repose sur des caractéristiques élémentaires qui peuvent être évaluées localement, comme le niveau de gris de chaque pixel ou des attributs estimés dans le voisinage du pixel, tels que la valeur moyenne, la variance ou des paramètres de texture.

I.7.1.1 Segmentation par Croissance de Région

La croissance des régions commence par l'ajout d'un ou plusieurs premiers pixels, appelés "seeds", et se développe progressivement en ajoutant des pixels adjacents qui répondent à un critère de similarité prédéfini. [5]




Figure I.4 : Croissance progressive d'une région



Figure I.5 : Résultat final de la croissance de régions

Critères de Croissance

✓ Intensité ou similarité de couleur : Des pixels adjacents présentant des valeurs d'intensité ou de couleur similaires sont ajoutés à la zone.

✓ La continuité spatiale : consiste à ajouter des pixels spatialement proches à la zone lorsque leur intensité ou leur couleur sont similaires.

✓ Caractéristiques texturales : Des pixels avec des caractéristiques texturales similaires sont ajoutés à la zone.

- **Avantages**

- Simple à comprendre et à mettre en pratique.
- Utile pour les photos avec des sections claires et bien définies.

- **Inconvénients**

- Sensible au choix des semences.

- Peut aboutir à des zones discontinues si les normes de ressemblance ne sont pas clairement spécifiées.

I.7.1.2 Segmentation par Fusion de Régions (Merge)

La segmentation basée sur la fusion de régions débute avec des régions initiales très petites (généralement des pixels individuels) et les fusionne progressivement afin de créer des régions plus grandes en fonction de critères de concordance. La fusion se poursuit jusqu'à ce qu'aucune région voisine ne réponde plus aux critères de similarité.

- **Avantages**

- Peut montrer la forme compliquée et irrégulière d'une région
- réduction du bruit grâce à la combinaison de pièces minuscules et insignifiantes.

- **Inconvénients**

- Le calcul peut être coûteux.
- La détermination des critères de fusion peut s'avérer difficile.

I.7.1.3 Segmentation par Division de Régions (Split)

Division selon la région L'image est d'abord divisée en régions qui la composent. Jusqu'à ce que chaque sous-région réponde à une exigence prédéterminée, cette région est divisée en sous-régions.

Critères de Division

➤ **Variance de l'intensité dans la région**

Les régions à forte variance sont divisées jusqu'à ce que la variance de chaque sous-région tombe en dessous d'un niveau prédéterminé.

➤ **Critères de texture ou de couleur**

La dissimilarité texturale ou colorimétrique est utilisée pour diviser les régions.

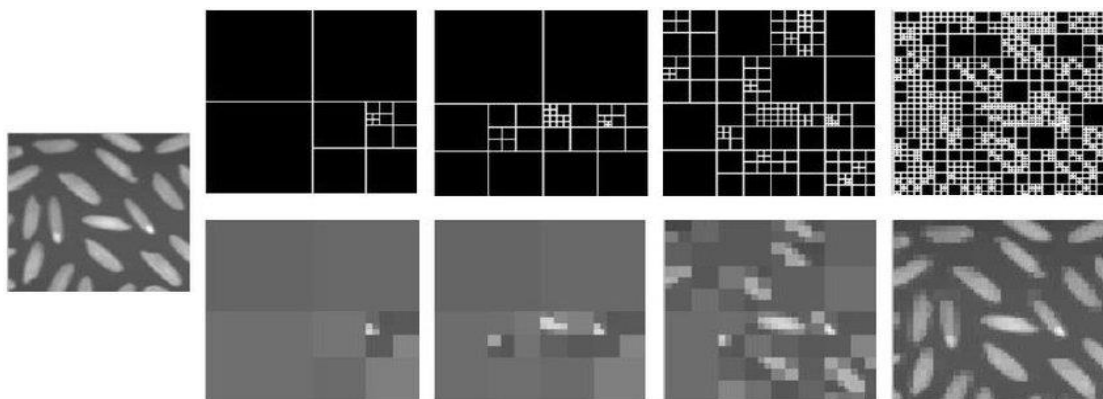


Figure I.6 : Exemple de segmentation par division de régions

- **Avantages**

- capacité à traiter des régions de taille variable.
- utile pour les photos présentant des sections uniformes et bien définies.

- **Inconvénients**

- Une sélection inadéquante des critères peut donner lieu à des régions indûment divisées, ce qui nécessite une étape de post-traitement pour les combiner.

I.7.1.4 Segmentation par division-fusion (Split and Merge)

Les deux méthodes précédentes sont combinées dans la méthode de séparation-fusion. Tout d'abord, des sous-régions homogènes de l'image sont séparées sur la base d'un critère de division. Ensuite, des segments homogènes plus larges sont formés en fusionnant les sections similaires proches.




Figure I.7: Agrégation itérative des blocs similaires au bloc 1

- **Inconvénients**

- ✓ Les zones obtenues ne sont pas, dans tous les cas, correspondantes aux objets représentés dans l'image.
- ✓ Les limites des zones obtenues sont généralement imprécises et ne correspondent pas exactement aux limites des objets de l'image.
- ✓ L'impossibilité de déterminer les critères pour regrouper les pixels ou fusionner et diviser les régions.

I.7.2 Segmentation Basée sur contours

Selon l'approche " contour ", les lignes de contraste qui séparent des zones aux nuances de gris variées et relativement uniformes, ou des zones aux textures variées, sont les primitives qu'il faut extraire. Il s'agit en fait d'identifier les zones de transition et de mieux situer la frontière entre les régions.

Les contours extraits ne sont généralement pas fermés ni même continus ; en fonction du résultat, il peut être nécessaire d'associer une méthode de fermeture ou de suivi des contours.




Figure I.8: quelques modèles de contours.

- Toit : il s'agit d'une ligne sur un fond uniforme.
- Marche d'escalier : le contour est net (contour idéal).
- Rampe : le contour est plus flou

Trois catégories peuvent être utilisées pour classer les nombreuses approches utilisées dans le cadre de la segmentation basée sur les contours Méthodes dérivatives, déformables et analytiques.

✓ Les méthodes dérivatives

Les méthodes dérivatives sont couramment employées pour repérer les transitions d'intensité à travers la différenciation numérique, que ce soit par la première ou la deuxième dérivée (voir figure ci-dessous). À chaque position de l'image, un opérateur est utilisé pour identifier les transitions significatives au niveau de l'attribut de discontinuité sélectionné. Le résultat est une image binaire composée de points de contour et de points sans contour.




Figure I.9 : contour et ses dérivées

En traitement d'images, il existe plusieurs opérateurs pour calculer les gradients (premières dérivées) et détecter les contours, parmi lesquels les opérateurs de Roberts, de Prewitt et de Sobel sont couramment utilisés.

✓ Les opérateurs de Roberts

Le détecteur Roberts permet de calculer rapidement et facilement le gradient bidimensionnel d'une image. Il agrandit les zones, souvent corrélées aux contours, où la norme de gradient spatial est significative. Ce principe ne diffère pas significativement de celui des opérateurs "Prewitt" et "Sobel". Par conséquent, l'opérateur "Roberts" estime le gradient localement sur la base des deux diagonales.

✓ Les opérateurs "Sobel" et "Prewitt"

Les opérateurs "Sobel" et "Prewitt" permettent d'estimer localement la norme de gradient spatial bidimensionnel d'une image en niveaux de gris. Ils agrandissent les zones avec des changements d'intensité locale importants en fonction des contours. Ces opérateurs consistent en une paire de masques de convolution en trois dimensions. L'application individuelle de chaque masque fournit une estimation des composants horizontaux et verticaux du gradient à l'aide d'un filtre linéaire simple et d'un masque 3x3. À partir de là, les composants du gradient peuvent être utilisés pour calculer la direction et la norme du gradient à chaque point. La norme du gradient estimé correspond ainsi à l'intensité attribuée au pixel correspondant. Ainsi, l'image de la norme du gradient qui est typiquement vue est ceci.

La figure suivante nous montre les contours détectés par ces filtres :[6]



Figure I .10: Détection de contour par les différents filtres

La figure suivante représente la détection de contour en utilisant le Laplacien [6] qui l'opérateur de Laplacien, basé sur la seconde dérivée.



Figure I .11: image originale (à gauche), contour détecté par Laplacien

✓ Les méthodes analytiques

Méthode de Canny et Deriche

L'algorithme a été conçu par John Canny en 1986 pour être optimal suivant trois critères clairement explicités :

1. bonne détection : faible taux d'erreur dans la signalisation des contours,
2. bonne localisation : minimisation des distances entre les contours détectés et les contours réels,
3. clarté de la réponse : une seule réponse par contour et pas de faux positifs [7]




Figure I .12 :Exemple d'application du filtre de CANNY

✓ Les méthodes déformables

Les méthodes déformables, également appelées active contours ou snakes, sont des techniques dynamiques qui modifient continuellement la forme d'un contour initial pour s'adapter aux contours des objets dans une image. Ces méthodes utilisent des courbes ou des surfaces qui évoluent sous l'influence de forces internes (qui assurent la régularité de la forme) et de forces externes (qui attirent le contour vers les caractéristiques de l'image, comme les bords).

Contours actifs

Dans cette approche que nous proposons, il s'agit de définir un contour fermé et de le faire progresser vers l'objet d'intérêt. Les déformations de cette courbe proviennent de la dérivation d'une fonctionnelle à optimiser qui caractérise l'objet. Les recherches concernant les contours actifs peuvent être classés en deux types : soit des méthodes basées exclusivement sur des informations de contour, soit des méthodes qui intègrent des caractéristiques sur les régions, ce qui permet d'obtenir des informations plus globales sur les objets à segmenter d'une image. [8]




Figure I .13 : (a) Le contour initial et (b) le contour à l'état de convergence

Cette courbe (Snake) est altérée par les trois forces ci-dessous :

- Une énergie propre : résultant exclusivement de la structure interne du contour.
- Une énergie potentielle : créée par l'image appelée énergie externe.

C'est elle qui va orienter la ligne du serpent vers les contours réels visibles sur l'image.

- Une énergie contextuelle : qui met en évidence certaines contraintes supplémentaires qui peuvent être imposées par l'utilisateur en fonction du serpent qu'il souhaite obtenir.

I.7.3 Segmentation Basée sur classification

Les techniques de segmentation pour la classification des pixels considèrent une région comme une collection de pixels connectés appartenant à la même classe. Elles créent un nuage de points dans l'espace attributaire en supposant que les pixels situés au même endroit ont des propriétés comparables.

La classification peut être supervisée ou non supervisée

- **Classification non supervisée**

Consiste en l'organisation d'individus en groupes homogènes. En gros, on définit des classes que l'on ne connaît pas à l'avance. [9]

Dans le domaine informatique et de l'intelligence artificielle, l'apprentissage non supervisé désigne la situation d'apprentissage automatique où les données ne sont pas étiquetées (par exemple étiquetées comme « balle » ou « poisson »). Il s'agit donc de découvrir les structures sous-jacentes à ces données non étiquetées. Puisque les données ne sont pas étiquetées, il est impossible à l'algorithme de calculer de façon certaine un score de réussite. Ainsi, les méthodes non supervisées présentent une auto-organisation qui capture les modèles comme des densités de probabilité ou, dans le cas des réseaux de neurones, comme combinaison de préférences de caractéristiques neuronales encodées dans les poids et les activations de la machine.

Les autres niveaux du spectre de supervision sont l'apprentissage par renforcement où la machine ne reçoit qu'un score de performance numérique comme guide, et l'apprentissage semi-supervisé où une petite partie des données est étiquetée.

- **Classification supervisée (Automatiques)**

Avant que les techniques supervisées puissent être utilisées sur un échantillon, elles doivent d'abord être apprises. Utilisez-les avec des données fraîches. Ce type de stratégie se compose de réseaux de neurones, de K-voisins les plus proches et de Vector Machine Support (SVM). Les méthodes supervisées nécessitent généralement une communication avec l'utilisateur afin de sélectionner l'échantillon d'apprentissage, la cause de la variabilité des résultats et reproductibilités. Mais ce type d'approche est inclus dans les méthodes fusionnées. Nous nous concentrerons sur la segmentation fondée sur l'approche dans ce projet. Nous allons présenter quelques algorithmes qui réagissent à la catégorisation supervisée, y compris l'algorithme pour les réseaux de neurones.

I.8 Conclusion

Les méthodes de segmentation d'images ont évolué considérablement, allant des techniques traditionnelles basées sur les seuils et les régions aux approches avancées basées sur l'apprentissage profond. Chaque méthode présente des avantages et des limitations spécifiques :

Simplicité et efficacité des méthodes traditionnelles : Les techniques de seuillage et de région sont rapides et faciles à mettre en œuvre, mais peuvent manquer de précision dans des conditions d'illumination variables et pour des images complexes.

Robustesse des méthodes basées sur les contours et le clustering : Ces méthodes sont plus robustes face aux variations de l'image, mais peuvent être sensibles aux paramètres de l'algorithme et nécessiter un prétraitement.

Précision des méthodes basées sur l'apprentissage profond : Les CNNs et leurs variantes offrent des performances supérieures pour la segmentation complexe, mais requièrent des ressources computationnelles importantes et de grandes quantités de données annotées pour l'entraînement.

Le choix de la méthode de segmentation dépend fortement des caractéristiques spécifiques de l'image à segmenter, des exigences de l'application et des ressources disponibles. Les avancées récentes en apprentissage profond ont considérablement amélioré la précision et la fiabilité de la segmentation d'images, ouvrant de nouvelles perspectives pour des applications variées allant de la médecine à la conduite autonome.

CHAPITRE II

Deep Learning

II.1 Introduction

Le Deep Learning fait partie de la machine Learning (ML), qui est lui-même un domaine de l'intelligence artificielle. Depuis les années 1950, le concept d'IA a été développé dans le but de rendre les ordinateurs capables de penser et de raisonner de manière similaire à celle des êtres humains. Afin de permettre aux machines de penser, le Deep Learning met l'accent sur leur apprentissage sans avoir recours à une programmation de manière explicite. L'apprentissage profond dépasse le machine Learning en développant des modèles hiérarchiques plus complexes visant à reproduire la manière dont les êtres humains assimilent de nouvelles informations.

Au cœur de l'apprentissage en profondeur se trouvent les réseaux de neurones artificiels, qui sont des modèles informatiques inspirés par le fonctionnement du cerveau humain. Ces réseaux sont constitués de différentes couches de neurones interconnectées, chaque couche effectuant des modifications sur les données provenant de l'extérieur. En particulier, les réseaux de neurones profonds se distinguent par leur aptitude à intégrer des représentations de données complexes en se basant sur des fonctions simples.

L'utilisation du Deep Learning associé au traitement d'image classique va aider à résoudre des applications telle la reconnaissance de panneaux de signalisation, la détection de pièces défectueuses, le dépistage de pathologies dans le domaine médical ou encore la détection d'anomalies sur des isolants électriques. Toutes ces applications n'avaient pas vraiment de solution fiable avant la mise en œuvre de cette nouvelle technologie basée sur un Réseau de Neurones Convolutifs (CNN).

L'utilité essentielle du Deep Learning est le traitement en masse de données pour augmenter la performance d'un algorithme et rendre un système de plus en plus intelligent et autonome.

Les domaines d'application sont nombreux : traduction, médecine, automobile, marketing, reconnaissance faciale, robotique....




Figure II .1: Artificial Intelligence Vs Machine Learning Vs Deep Learning

II.2 Définition de l'apprentissage profond (Deep Learning)

Le Deep Learning est une fonction de l'intelligence artificielle qui imite le fonctionnement du cerveau humain dans le traitement des données et la création de modèles à utiliser dans la prise de décision.

L'apprentissage profond est une méthode d'apprentissage automatique qui utilise des réseaux de neurones artificiels multicouches pour modéliser et apprendre à partir de données complexes. Ces réseaux, inspirés par la structure du cerveau humain, sont capables de découvrir des schémas et des relations dans les données en passant par plusieurs couches de traitement.

L'apprentissage profond a connu une popularité croissante en raison de sa capacité à résoudre efficacement des problèmes complexes dans des domaines tels que la vision par ordinateur, le traitement du langage naturel et bien d'autres.

Pourquoi le deep Learning ?

La réponse à cette question est vraiment essentielle, elle nous permet de comprendre l'engouement autour du deep Learning. Le graphe ci-dessus l'explique clairement.

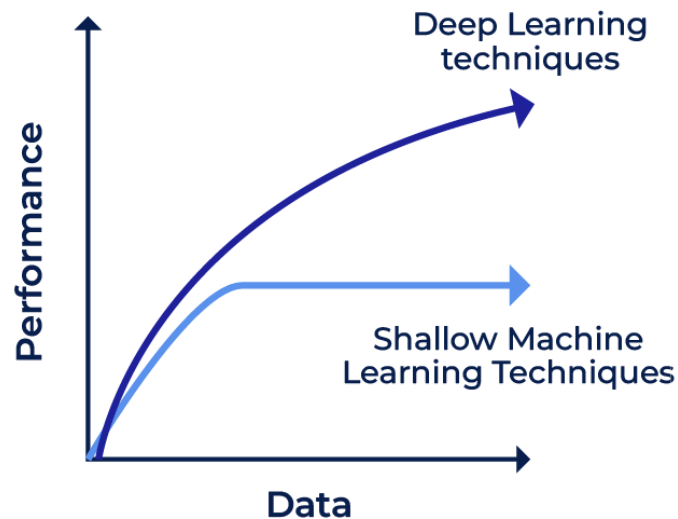


Figure II .2: Le graphe entre Deep learning vs Machine learning.

Illustration de la performance des Algorithmes Deep Learning vs Machine Learning par rapport à la quantité de données.

Les algorithmes d'apprentissage automatique traditionnels ne sont pas utiles lorsque nous travaillons avec des données de grande dimension où nous disposons d'un grand nombre d'entrées et de sorties. L'apprentissage profond est très efficace dans ce cas.

✓ **Différence entre Deep Learning et Machine Learning**

Le deep learning est un type ou (variante) spécialisé de l'apprentissage automatique. Le début d'un processus d'apprentissage automatique consiste à extraire manuellement les fonctionnalités pertinentes des images.

Ensuite, les caractéristiques sont exploitées afin de concevoir un modèle qui organise les objets dans l'image. Grâce à un processus d'apprentissage approfondi, les caractéristiques pertinentes sont automatiquement extraites des images.

De plus, le deep learning réalise un "apprentissage complet" - où un réseau reçoit des données brutes et une tâche à accomplir, comme la classification, et intègre automatiquement cette tâche.

L'autre distinction majeure réside dans le fait que les algorithmes d'apprentissage en profondeur évoluent en fonction des données, tandis que le Shallow Learning (apprentissage peu profond) se rapprochent. Le terme "Shallow Learning" désigne les techniques

d'apprentissage automatique qui peuvent améliorer leurs performances en ajoutant davantage d'exemples et de données de formation au réseau.

Les réseaux d'apprentissage profond présentent un avantage majeur : ils continuent fréquemment de progresser à mesure que la taille de vos données augmente.




Figure II 3: Différence entre Deep learning et Machine learning

Le Machine Learning et le Deep Learning sont deux types d'intelligence artificielle. Le Machine Learning est une IA capable de s'adapter automatiquement avec une interférence humaine minimale, et le Deep Learning est un sous-ensemble du Machine Learning utilisant les réseaux de neurones pour mimer le processus d'apprentissage du cerveau humain. La principale différence entre le deep learning et le machine learning réside dans la complexité des données et les méthodes utilisées pour les traiter, le deep learning étant mieux adapté aux données non structurées et aux modèles complexes²².

II.3 Fonctionne du Deep Learning

Le Deep Learning est une catégorie d'intelligence artificielle qui exploite des réseaux de neurones artificiels, inspirés directement du fonctionnement des neurones humains, pour assimiler de nouvelles connaissances. Ces réseaux sont constitués de plusieurs couches de neurones artificiels connectés entre eux [10]. Chaque couche joue un rôle spécifique dans le traitement des informations [11]. Au sein d'un réseau artificiel, le principe est similaire à celui du cerveau humain, où chaque neurone reçoit environ 100 000 signaux électriques des autres neurones [12].

Les modèles de Deep Learning sont entraînés en utilisant de grands jeux de données labellisées et peuvent souvent apprendre des caractéristiques, directement à partir des données, sans qu'il soit nécessaire de les extraire manuellement. Alors que le premier réseau de neurones artificiels a été théorisé en 1958, le Deep Learning nécessite une puissance de calcul importante qui n'était pas disponible avant les années 2000. Aujourd'hui, les chercheurs ont accès à des ressources informatiques qui permettent de construire et d'entraîner des réseaux comportant des centaines de neurones et de connexions.

II.4 Les architectures de Deep Learning

Les architectures de Deep Learning telles que les réseaux neuronaux profonds, les réseaux de croyances profondes, les réseaux neuronaux récurrents et les réseaux neuronaux convolutifs ont été appliquées à des domaines tels que :

- La vision par ordinateur.
- La reconnaissance vocale.
- Le traitement du langage naturel.
- La reconnaissance audio.
- Le filtrage des réseaux sociaux.
- La traduction automatique.
- La bio-informatique.
- La conception de médicaments.
- L'analyse d'images médicales.
- L'inspection des matériaux.
- Les programmes de jeux de société, où elles ont produit des résultats comparables et, dans certains cas, supérieurs aux performances des experts humains.

II.5 Introduction sur Réseaux de neurones

Le nom « **réseau de neurones** » est inspiré du réseau complexe de neurones du cerveau humain et de la façon dont les neurones communiquent.

Les réseaux de neurones sont un sous-groupe de l'apprentissage automatique, qui utilise des algorithmes d'apprentissage en profondeur pour développer le noyau du réseau

Le réseau neuronal utilise ses données d'entraînement comme données d'entrée pour soutenir l'apprentissage et améliorer ses capacités. Il permet un apprentissage constant à partir

de données antérieures avec une précision croissante, ce qui en fait un outil puissant et moderne...

✓ **Les neurones sont regroupés en trois types de couches différentes :**

- La couche d'entrée – input layer.
- La ou les couche(s) cachée(s) – hidden layer(s).
- La couche de sortie – output layer.
- La couche d'entrée (input layer) reçoit les données d'entrée.




Figure II . 4 : Exemple de réseau de neurones

Le nombre de couches, et le nombre de neurones constituant chaque couche, sont une science à part entière, très complexe. Il est d'ailleurs impossible de définir avec exactitude le nombre

« Parfait » de couches et de neurones.

Cela est en tout cas le cas pour les couches du milieu, appelées « couches cachées ». Pour la première et dernière couche, appelées « couches visibles », le nombre de neurones est simple à définir :

- il doit y avoir autant de neurones dans la première couche qu'il n'y a d'informations en entrée (ex: nombre de pixels de l'image à analyser).
- il doit y avoir autant de neurones dans la dernière couche qu'il n'y a d'informations en sortie (ex: nombre de choix possibles).

II.6 Les réseaux de neurones convolutifs

Depuis des dizaines d'années, les chercheurs en IA s'appliquent à inculquer aux machines l'intelligence au niveau des humains. D'une certaine manière, ils ont réussi à développer des capacités cognitives comme le traitement du langage ou la perception visuelle. Et derrière toutes ces avancées se tiennent différentes techniques qui permettent aux machines d'agir sans intervention humaine.

Les réseaux de neurones convolutifs (CNNs) sont un type de réseau de neurones artificiels utilisés principalement pour analyser des images. Ils sont composés de plusieurs couches qui filtrent et transforment progressivement l'entrée (par exemple, une image) pour identifier des caractéristiques importantes comme les contours, les textures, et finalement des objets spécifiques.

Les réseaux neuronaux convolutifs sont spécialisés dans le traitement des données en grille [13], en particulier des images, avec une grande efficacité et précision. Ils sont largement utilisés dans divers domaines tels que les diagnostics médicaux.

Un réseau neuronal convolutif est un algorithme de Deep Learning utilisé pour les tâches de classification et de computer vision. Il permet d'apprendre directement à partir des données sans avoir à extraire les caractéristiques manuellement. Le réseau neuronal convolutif (CNN ou ConvNet) est une architecture réseau pour le Deep Learning qui apprend directement à partir des données [14]. Ce type de réseau est particulièrement efficace lorsqu'il s'agit de trouver des patterns dans des images afin de reconnaître des objets, des classes et des catégories [14]. Les réseaux convolutifs s'inspirent de la nature, car la connectivité entre les neurones artificiels ressemble à l'organisation du cortex visuel animal [15]. Les réseaux convolutifs apprennent plus rapidement et ont un meilleur taux d'erreur [15].

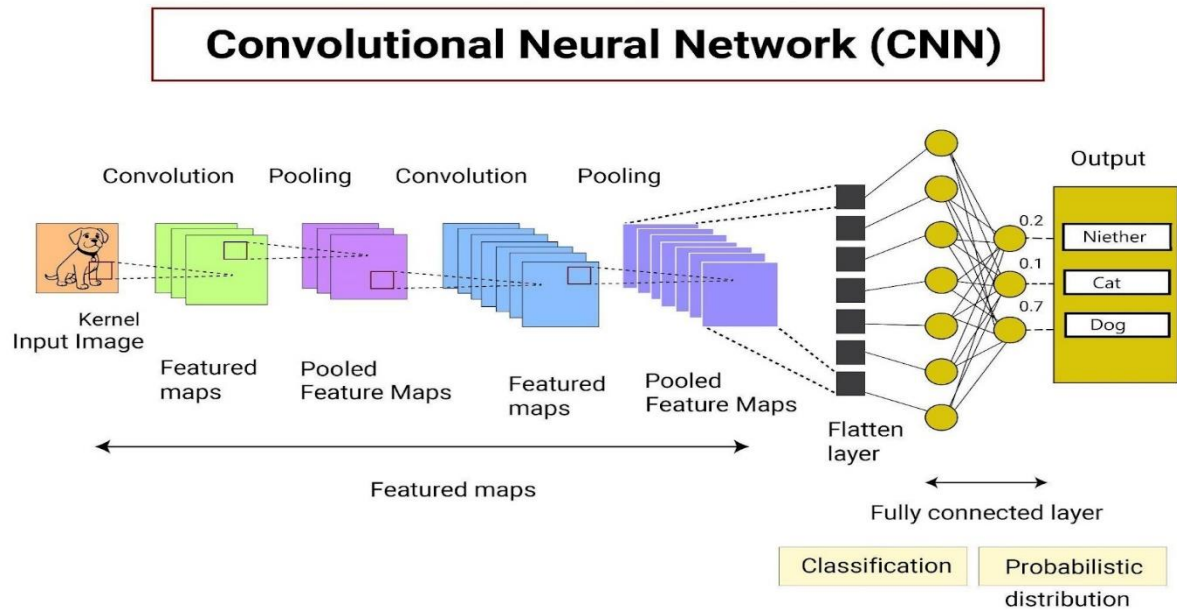


Figure II. 5 : Convolution Neural Network.

II.7 Les principaux composants du CNN

Les réseaux de neurones convolutionnels ont une architecture différente de celle des réseaux de neurones réguliers. Généralement, les réseaux de neurones convolutionnels sont composés de trois types principaux de couches; les couches convolutives, les couches de sous échantillonnage et les couches entièrement connectées.

La principale distinction entre le machine learning et le deep learning est le nombre de couches. Plus ce nombre augmente, plus l'apprentissage devient complexe. De ce fait, un réseau neuronal convolutif comporte aussi plusieurs couches pouvant aller de dizaines à des centaines.

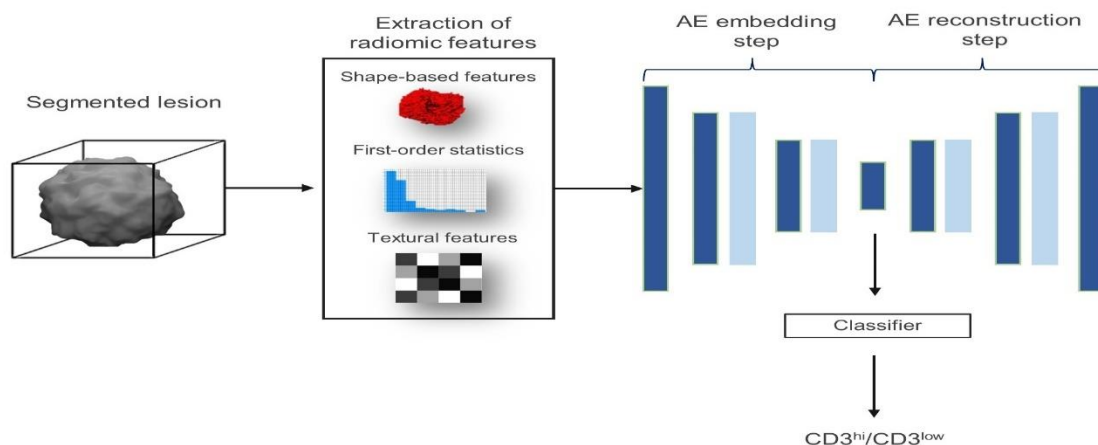


Figure II. 6 : Les principaux composants du CNN.

Les couches correspondent à des filtres qui modifient les données d'entrée afin d'extraire les caractéristiques spécifiques. Elles comprennent également une couche d'entrée et de sortie ainsi que des couches cachées. Un réseau neuronal convolutif peut comprendre trois types de couches (en anglais Layers) composent le CNN : convolution layers, pooling layers et fully-connected layers (FC).

Lorsque ces couches sont empilées, une architecture CNN est formée. En plus de ces trois couches, il y a trois paramètres plus importants qui sont dropout layers, the activation fonction et loss fonction qui sont définis ci-dessous :

II .7.1. Les couches de CNN

➤ La couche convolutionnelle (convolution Layers ou CONV)

Le rôle de cette première couche est d'analyser les images fournies en entrée et de détecter la présence d'un ensemble de caractéristiques. Son objectif final est d'extraire des caractéristiques propres à chaque image en les compressant de façon à réduire leur taille initiale. En résumé, l'image fournie en entrée passe à travers une succession de filtres, créant par la même occasion de nouvelles images appelées cartes de convolutions. Enfin, les cartes de convolutions obtenues sont concaténées dans un vecteur de caractéristiques appelé code CNN.

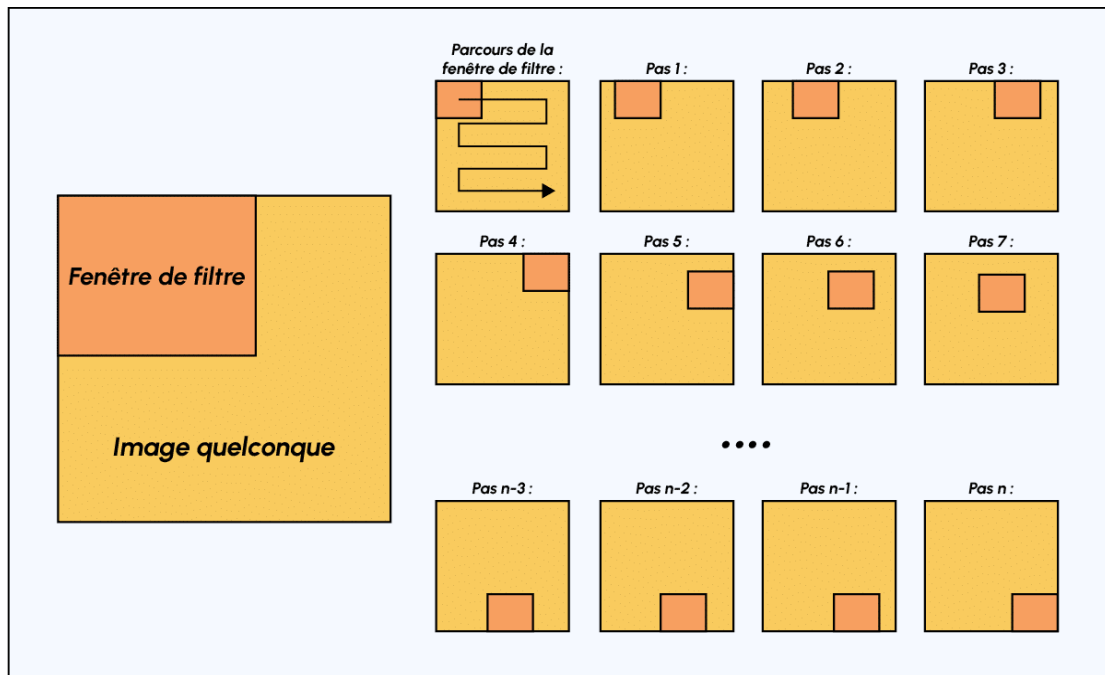


Figure II. 7 : Schéma du parcours de la fenêtre de filtre sur l'image.

➤ la couche de pooling (pooling Layers) :

La couche de Pooling est une opération généralement appliquée entre deux couches de convolution.

Le code CNN obtenu en sortie de la partie convolutive est fourni en entrée dans une deuxième partie, qui consiste à réduire progressivement la taille de l'image en ne gardant que les informations les plus importantes, par exemple pour chaque groupe de 4 pixel, le pixel ayant la valeur maximale (Max Pooling, le plus populaire) ou la moyenne des pixels (AVG pooling).

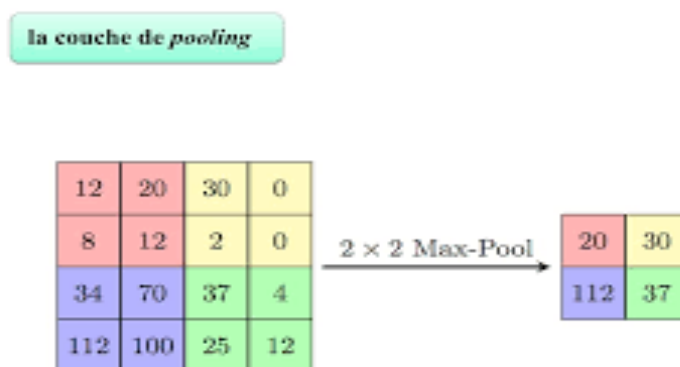


Figure II 8 : la couche de Pooling.

Avec la couche pooling, la quantité de paramètres et de calcul dans le réseau sont réduits, et cela va permettre de contrôler le sur-apprentissage.

Après avoir extrait les caractéristiques des entrées, on attache à la fin du réseau un perceptron ou bien un MLP (Multi Layer perceptron) communément appelé Fully connected.

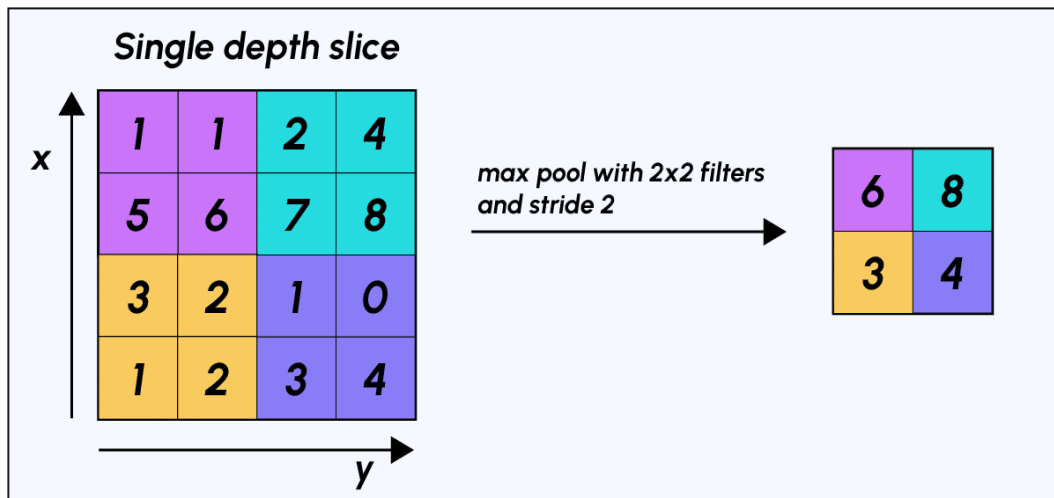


Figure II. 9 : Processus de Max-Pooling.

➤ La couche d'activation (Rectified Linear Units) (Relu) :

L'on fait passer les cartes de convolution à travers une couche d'activation non linéaire telle que Rectified Linear Unit (Relu), qui consiste à remplacer les nombres négatifs des images filtrées par des zéros [16].

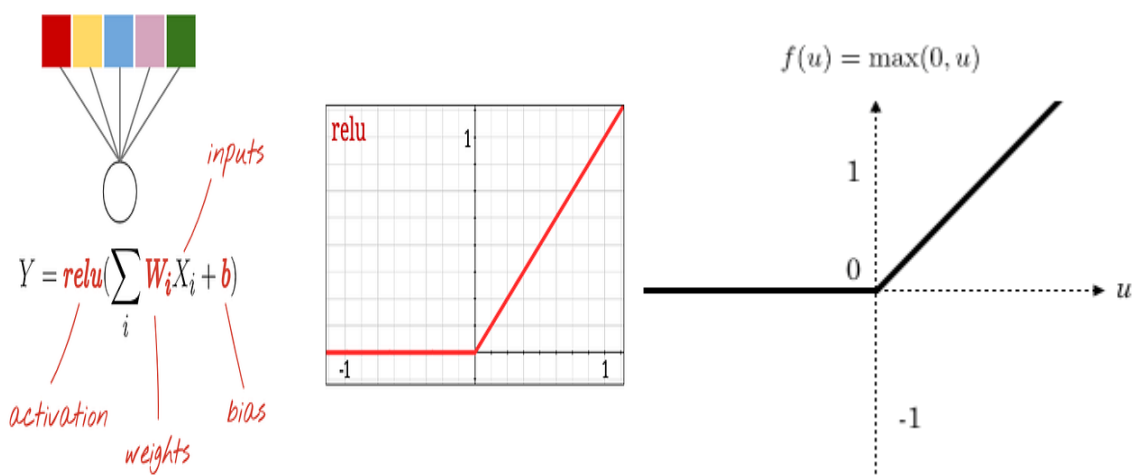


Figure II. 10 : Fonction d'activation Relu.

➤ La couche entièrement connectée (Fully Connected Layers ou FC) :

Ces couches sont placées à la fin de l'architecture CNN et sont entièrement connectées à tous les neurones de sortie (d'où le terme entièrement connecté).

Dans cette couche, la valeur des pixels de l'image d'entrée est directement liée à la valeur de la matrice de sortie. Autrement dit, il s'agit d'une couche de classification qui utilise la technologie Softmax. Comme les couches convolutives et de pooling, une couche entièrement connectée peut-être suivie de plusieurs couches qui répètent le même processus dans le but d'extraire plus de fonctionnalités [17].




Figure II. 11: Fully-connected Layer.

II.8 Architecture de CNN

Il y a deux parties principales dans une architecture CNN : [18]

- Un outil de convolution qui sépare et identifie les différentes caractéristiques de l'image pour analyse dans un processus appelé Extraction de caractéristiques.
- Le réseau d'extraction de fonctionnalités se compose de nombreuses paires de couches convolutives ou de pooling.
- Une couche entièrement connectée qui utilise le résultat du processus de convolution et prédit la classe de l'image en fonction des caractéristiques extraites lors des étapes précédentes.

- Ce modèle CNN d'extraction de fonctionnalités vise à réduire le nombre de fonctionnalités présentes dans un ensemble de données. Il crée de nouvelles fonctionnalités qui résument les fonctionnalités existantes contenues dans un ensemble original de fonctionnalités. Il existe de nombreuses couches CNN, comme le montre le diagramme d'architecture CNN.

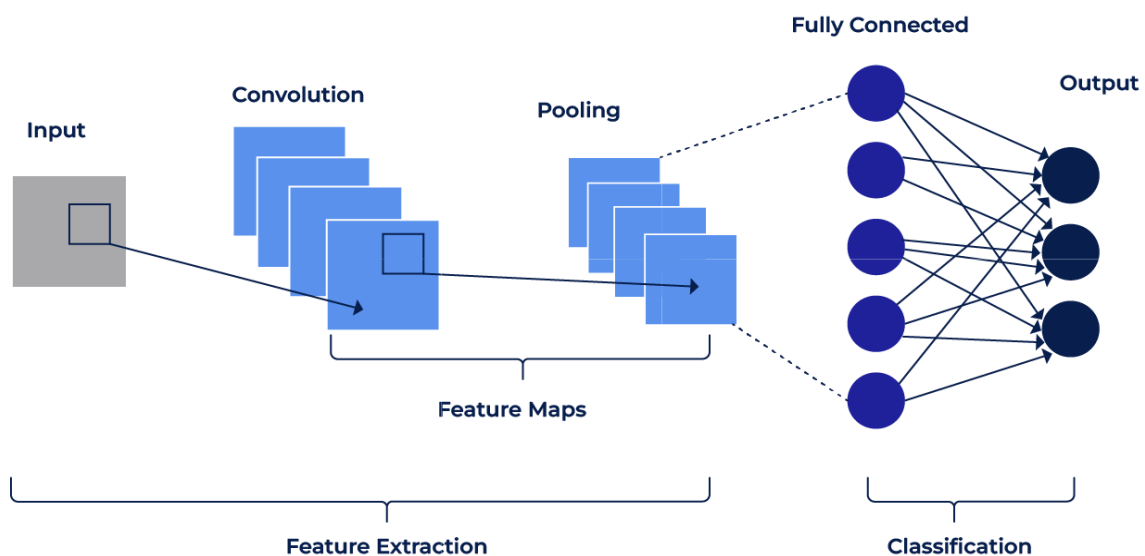


Figure II. 12 : Architecture d'un réseau de neurones CNN.


II.8.1. Architecture U-Net

L'architecture U-Net est une architecture de réseau de neurones convolutifs (CNN) spécifiquement conçue pour la segmentation d'images, c'est-à-dire la tâche de prédire pour chaque pixel d'une image à quelle classe il appartient. Développée initialement pour la segmentation d'images biomédicales, U-Net a rapidement gagné en popularité dans divers domaines en raison de sa performance robuste, surtout dans les cas où les données d'entraînement sont limitées.

Le réseau U-Net tire son nom de sa forme distinctive en "U". Cette architecture comporte deux chemins : un chemin contractant (ou de descente) qui capture le contexte et un chemin symétrique d'expansion (ou de montée) qui permet une localisation précise. La dénomination "U-Net" est donc directement inspirée par cette conception architecturale, où la forme en "U" est centrale pour la fonctionnalité du réseau.

À chaque étape du downsampling, nous doublons le nombre de canaux de fonctionnalités. Toutes les étapes de la voie élargie sont constituées d'un échantillonnage de la carte des caractéristiques suivi d'une convolution 2x2 (« up-convolution ») qui réduit le

nombre de canaux de caractéristiques, d'une concaténation avec la carte des caractéristiques correspondante mentcroppede de la voie de contraction, et de deux convolutions 3x3, chacune suivie d'une Relu. Il est nécessaire de cropper en raison de la perte des pixels de bord lors de chaque convolution. Au niveau final, on utilise une convolution 1x1 pour aligner chaque Vector de caractéristiques 64-composantes avec le nombre de classes souhaité. Au total, le réseau comprend 23 niveaux de convolution.



L'U-Net est une architecture réseau conventionnelle pour une segmentation rapide et précise des images. Jusqu'à présent, il a surpassé toutes les méthodes précédentes surtout dans le domaine médical et la détection des anomalies et des tumeurs.

II.9 Avantages d'un CNN dans le domaine de la reconnaissance d'images

Comparé aux réseaux neuronaux conventionnels, le CNN offre de nombreux avantages :

- Il est adapté aux applications de machine learning et d'intelligence artificielle qui nécessitent de grandes quantités de données d'entrée, comme la reconnaissance d'images.
- Le réseau opère de manière solide et ne subit pas de distorsion ou d'autres modifications optiques.
- Il est capable de traiter des images capturées dans diverses conditions d'éclairage et à différentes angles de vue. Les traits caractéristiques d'une image sont donc aisément repérés.
- Son espace de stockage est nettement inférieur à celui des réseaux de neurones entièrement maillés. Il y a plusieurs couches locales partiellement maillées dans le CNN. Les couches de convolution permettent une diminution significative des besoins de stockage.
- Le temps nécessaire pour la formation d'un CNN est également nettement diminué. En utilisant des processeurs graphiques modernes, il est possible de former les CNN de manière extrêmement efficace.
- Il s'agit de la technologie de pointe pour l'apprentissage profond et la classification dans le domaine de la reconnaissance d'images.

II.10 Paramètres de CNN

Les paramètres d'un réseau de neurones convolutionnels (CNN) comprennent généralement les filtres (kernels), la taille des filtres, le pas (stride), le padding, le nombre de couches, les fonctions d'activation et la méthode de pooling.

II.11. Conclusion

Dans ce chapitre, nous avons exploré les bases et les applications des réseaux de neurones convolutifs (CNN) ainsi que des architectures U-Net, mettant en lumière leurs avantages et paramètres spécifiques. Les CNN se sont avérés être des instruments puissants pour la reconnaissance d'images, capables de traiter de vastes quantités de données et de s'adapter à diverses conditions. Parmi leurs avantages figurent une robustesse contre les distorsions

optiques, une efficacité en termes de stockage et de temps de formation, ainsi qu'une grande précision dans la classification des images.

L'architecture U-Net se distingue par sa capacité à segmenter les images pixel par pixel avec une précision élevée, même avec un nombre limité de données d'entraînement, grâce à des techniques d'augmentation de données. Sa facilité de mise en œuvre et sa robustesse en font un outil précieux dans des domaines spécialisés comme la détection des anomalies médicales.

En combinant des couches convolutives, de pooling, d'activation et entièrement connectées, ces technologies permettent de créer des modèles capables d'extraire et d'analyser des caractéristiques complexes des images. L'évolution continue des réseaux de neurones et des techniques de deep learning ouvre la voie à de nouvelles avancées dans le traitement et l'analyse des données visuelles, promettant des applications innovantes et efficaces dans divers secteurs.

CHAPITRE III

Résultats

III.1 Introductions

La segmentation est une tâche fondamentale en vision par ordinateur avec diverses applications allant de l'imagerie médicale à la conduite autonome. La capacité de délimiter avec précision des objets ou des régions d'intérêt dans les images est cruciale pour comprendre leur contenu et extraire des informations significatives. Ces dernières années, les techniques de deep learning ont révolutionné le domaine de la segmentation d'images, avec des architectures comme U-Net démontrant des performances remarquables dans divers domaines.

Le but de cette étude est d'étudier l'efficacité d'U-Net, une architecture de réseau de neurones convolutifs, dans la tâche de segmentation d'image. U-Net a acquis une grande attention pour sa capacité à capturer des dépendances spatiales complexes dans les images tout en gérant efficacement les tâches de segmentation sémantique. En tirant parti de son architecture encodeur-décodeur et de ses connexions sautées, U-Net a obtenu des résultats prometteurs en segmentant les objets d'intérêt avec une grande précision spatiale.

L'importance de cette recherche réside dans son potentiel à faire progresser l'état de l'art dans la segmentation de l'image et à contribuer à diverses applications du monde réel. En évaluant la performance d'UNet sur des tâches de segmentation difficiles, nous visons à découvrir ses forces et ses limites, ouvrant la voie à de futures améliorations et innovations dans ce domaine.

Dans cette introduction, nous donnons un aperçu de l'importance de la segmentation d'image, de l'évolution des techniques d'apprentissage profond dans ce domaine et de la raison d'être de notre choix de l'U-Net comme point focal de notre enquête. Les chapitres suivants approfondiront la méthodologie, les résultats expérimentaux et les discussions, aboutissant à une compréhension complète des capacités de l'U-Net dans les tâches de segmentation d'images. À travers cette étude, nous nous efforçons de mettre en lumière le potentiel des approches d'apprentissage profond pour faire progresser le domaine de la vision par ordinateur et relever le défi du monde réel.

III.2 la base de données utilisée

Nous avons utilisé pour cette étude une partie des images ultra-sound du cancer du sein de la base 'Kaggle'. Le cancer du sein est l'une des causes de décès les plus courantes chez les femmes dans le monde. La détection précoce permet de réduire le nombre de décès

prématurés. Les données examinent les images médicales du cancer du sein à l'aide d'une échographie. L'ensemble de données d'échographie mammaire est classé en trois classes : images normales, bénignes et malignes. Les images échographiques mammaires peuvent produire d'excellents résultats dans la classification, la détection et la segmentation du cancer du sein lorsqu'elles sont combinées à l'apprentissage automatique.

Pour télécharger une base de données depuis Kaggle, voici les étapes à suivre :

- Créez un compte dans Kaggle en utilisant un e-mail pour accéder à la page de l'ensemble de données. [19]
- Sélectionnez et téléchargez la base de données que vous souhaitez utiliser.
- Pour importer la base de données que nous utilisons Google Colab, nous devons d'abord contacter Google Colab.
- Utilisez Google Colab pour importer la base de données.
- Et pour importer la base de données : une fois que vous avez exécuté le script Python, vous pouvez importer la base de données dans Google Colab à l'aide de la commande `pip install Kaggle` pour installer le package Kaggle, puis à l'aide de la commande `kaggle datasets download` pour télécharger la base de données.

III .3 Logiciel d'utilisée

Tout le programme était de développement à PYTHON et Google Colab

III .3 .1 Python

Python est un **langage de programmation puissant et facile à apprendre**. Il dispose de structures de données de haut niveau et permet une approche simple mais efficace de la programmation orientée objet. [20]

Le logiciel Python est plus qu'un simple langage de programmation. Il s'agit d'un écosystème complet comprenant un langage de programmation polyvalent, une bibliothèque standard riche en fonctionnalités et une communauté mondiale active.

Depuis sa création en 1991 par Guido van Rossum, Python a gagné en popularité pour devenir l'un des langages de programmation les plus utilisés à travers le monde.

III .3.2 Google Colab

Google Colab, abrégé en Google Colaboratory, est une plateforme cloud fournie par Google qui permet aux utilisateurs de créer et d'exécuter du code Python dans un environnement interactif basé sur le navigateur. Avec son accès gratuit à des ressources

informatiques, telles que des GPU et des TPU accélérateurs, il est parfait pour l'apprentissage automatique, l'analyse de données et les projets de recherche collaboratifs. Grâce à Google Colab, les utilisateurs peuvent créer et partager des notebooks Jupyter, collaborer en temps réel avec d'autres utilisateurs, et utiliser des bibliothèques et des outils pré-installés, tout cela sans avoir besoin d'installer localement ou de configurer.

➤ **Colab permet :**

- D'améliorer vos compétences de codage en langage de programmation Python.
- De développer des applications en Deep Learning en utilisant des bibliothèques Python populaires telles que Keras, TensorFlow, PyTorch et OpenCV.
- D'utiliser un environnement de développement (Jupyter Notebook) qui ne nécessite aucune configuration.

Mais la fonctionnalité qui distingue Colab des autres services est l'accès à un processeur graphique GPU, totalement gratuitement ! Des informations détaillées sur le service sont disponibles sur la page FAQ de Colab.

De plus, les documents Colab (Jupyter Notebook) sont enregistrés directement votre compte Google Drive.

III. 4 Méthodologie

L'objectif de notre recherche est de développer un modèle d'apprentissage profond visant à améliorer la précision de la segmentation du cancer du sein, avec un accent particulier sur la détection des tumeurs petites et irrégulières. Nous proposons l'utilisation d'Attention U-Net comme méthode prometteuse pour atteindre cet objectif. Notre approche innovante exploite le mécanisme d'attention pour améliorer la précision de la segmentation du cancer du sein. Ce mécanisme permet à Attention U-Net de se concentrer sur les régions les plus critiques de l'image, améliorant potentiellement la précision de la segmentation.

Notre travail introduit plusieurs aspects nouveaux :

Utilisation d'un vaste ensemble de données de mammographie : nous formons Attention U-Net sur un vaste ensemble de données de mammographies incluant des cas de cancer du sein. Cette formation approfondie permet au modèle de reconnaître les caractéristiques subtiles indicatives du cancer du sein, même celles qui ne sont pas facilement visibles à l'œil humain.

Évaluation des performances sur un ensemble de données conservé : Nous évaluons rigoureusement les performances d'Attention U-Net à l'aide d'un ensemble de données distinct

et conservé de mammographies avec le cancer du sein. Nos résultats indiquent que l'Attention U-Net surpasse l'U-Net traditionnel en segmentant avec précision les tumeurs petites et irrégulières. [21]

III.5 Dataset Description

Les données collectées au départ comprennent des images d'échographie mammaire chez des femmes âgées de 25 à 75 ans. Ces données ont été collectées en 2018. Le nombre de patientes est de 600. L'ensemble de données se compose de 780 images avec une taille d'image moyenne de 500*500 pixels. Les images sont au format PNG. Les images de vérité terrain sont présentées avec les images originales. Les images sont classées en trois catégories : normales, bénignes et malignes.

Tableau III.1 : Nombre de photos et de masques

Ce tableau montre le nombre d'images et de masques pour chaque catégorie ainsi que le total Pour chacune :

- Catégorie Naturel : contient 133 images et 133 masques.

Catégorie	Nombre de photos	Nombre de masques
naturel	133	133
bénigne	437	454
maligne	210	211
Total	780	798

- Catégorie bénigne : contient 437 images et 454 masques.
- Catégorie malveillante : contient 210 images et 211 masques.
- Total : contient 780 images et 798 masques

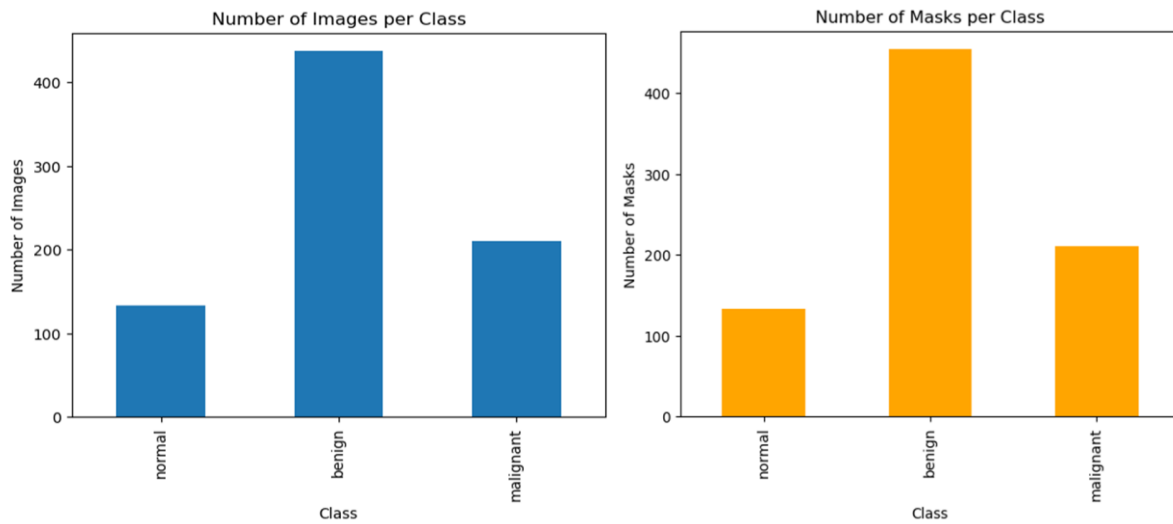
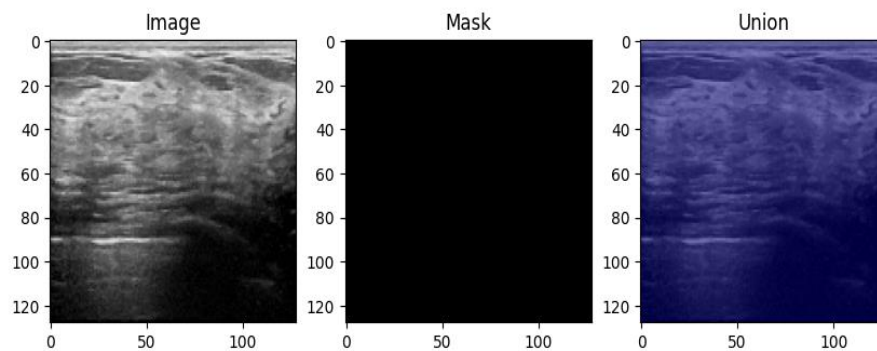


Figure III.1 : Répartition du nombre d'images et de masques pour chaque catégorie


III.6 Segmentation Résultats

Nous avons présenté ici les images avec les masques et l'union pour les différentes classes.

Normal class



Benign class



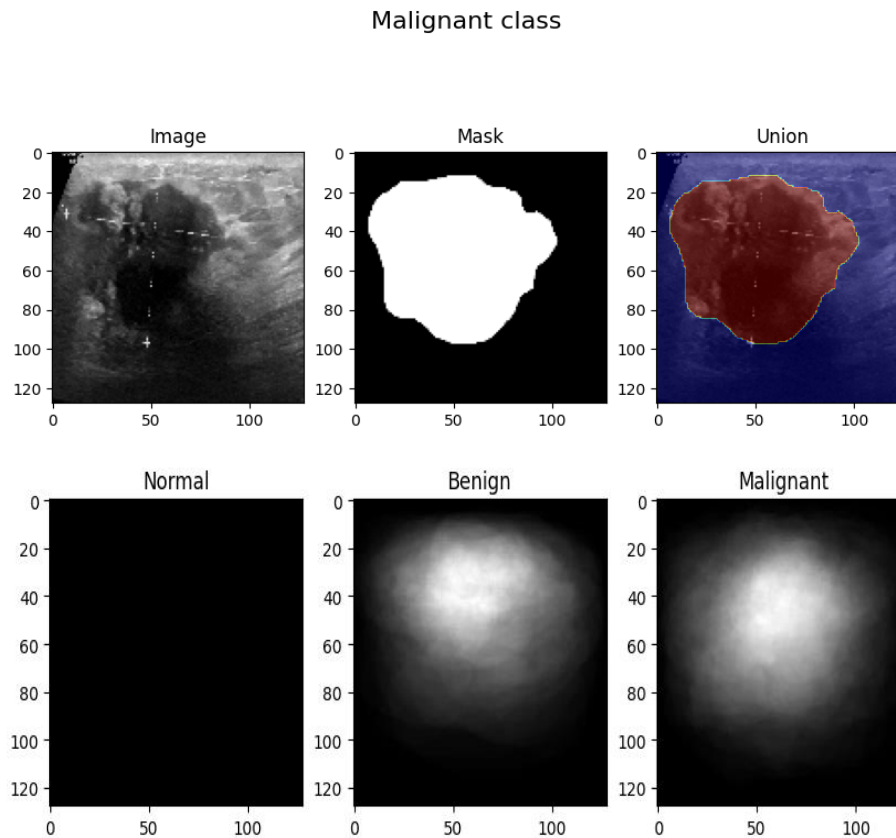


Figure III.2 : Représentation visuelle de chaque classe

III.7 Prétraitement des données

Élimination de la classe standard : La classe standard est éliminée car elle ne comporte aucun masque. La raison en est que l'objectif de la tâche de classification est de différencier les tumeurs bénignes des tumeurs malignes, et que la classe normale n'offre aucun aperçu de ces deux catégories.

Combinaison de masques pour la même image : La valeur maximale de chaque pixel est utilisée pour combiner tous les masques existant pour la même image. En raison de la probabilité de chevauchement des masques, l'adoption de la valeur maximale garantit que le masque combiné représente avec précision l'ensemble de la tumeur.

Les étapes du prétraitement des données sont les suivantes :

- Importer les masques et les images.
- Retire la classe normale.
- Fusionnez les masques pour la même image.
- Stocker les images et les masques édités

III.8 Train - Test Divisé

L'une des méthodes d'évaluation des performances d'un modèle d'apprentissage automatique est la division formation-test.

Un ensemble de formation et un ensemble de test sont créés en divisant les données en deux groupes. L'ensemble de formation et l'ensemble de test sont utilisés pour former et tester le modèle. Les données ont été réparties à raison de 90/10 entre l'ensemble d'entraînement et l'ensemble de test.

En d'autres termes, 10 % seulement des données ont été utilisées pour tester le modèle après que 90 % des données ont été utilisées pour le former.

Il s'agit d'une résolution de 128 x 128 avec une résolution de 128 x 128 et une résolution de 128 x 128.

III.9 Modèle d'apprentissage automatique




Figure III.3: U-Net Convolutional Networks

Architecture U-Net (exemple pour 32x32 pixels dans la résolution la plus basse). Chaque boîte bleue correspond à une carte de caractéristiques multicanaux. Le nombre de canaux est indiqué en haut de la boîte. La taille x-y est indiquée sur le bord inférieur gauche de la boîte. Les cases blanches représentent des cartes de caractéristiques copiées. Les flèches indiquent les différentes opérations.

Cette illustration est un exemple de l'architecture U-Net, mais les couches peuvent avoir des tailles différentes.

III.10 Entraînement du modèle

Le modèle a été entraîné à l'aide de données préalablement préparées pour 50 époques

Epoch 1/50 19/19 [=====]	- 49s 968ms/step - loss: 1.4710 - accuracy: 0.8430 - val_loss: 0.3524 - val_accuracy: 0.9067
Epoch 10/50 19/19 [=====]	- 7s 371ms/step - loss: 0.2121 - accuracy: 0.9060 - val_loss: 0.2081 - val_accuracy: 0.9215
Epoch 20/50 19/19 [=====]	- 7s 363ms/step - loss: 0.1179 - accuracy: 0.9533 - val_loss: 0.1274 - val_accuracy: 0.9521
Epoch 30/50 19/19 [=====]	- 7s 367ms/step - loss: 0.0836 - accuracy: 0.9658 - val_loss: 0.0968 - val_accuracy: 0.9610
Epoch 40/50 19/19 [=====]	- 7s 367ms/step - loss: 0.0509 - accuracy: 0.9787 - val_loss: 0.0930 - val_accuracy: 0.9671
Epoch 50/50 19/19 [=====]	- 7s 366ms/step - loss: 0.0406 - accuracy: 0.9820 - val_loss: 0.1367 - val_accuracy: 0.9611

Figure III.4 : Visualisation de l'apprentissage.

III.11 Évaluation des performances




Figure III.5 : Perte et Précision

Loss (à gauche)

- **Perte d'entraînement** : La ligne bleue représente la perte d'entraînement. Elle commence à une valeur élevée d'environ 1,4 et diminue rapidement au cours des premières époques. Elle continue ensuite à diminuer plus graduellement, atteignant une valeur faible proche de 0 à la 50e époque. Cela indique que le modèle minimise efficacement la perte sur les données d'apprentissage.
- **Perte de validation** : La ligne orange représente la perte de validation. Elle commence également par une valeur élevée et diminue de manière significative au cours des

premières époques. Cependant, il y a quelques fluctuations tout au long des époques, ce qui indique que la perte de validation ne diminue pas de manière aussi régulière que la perte d'apprentissage. Cette fluctuation peut être le signe d'un surajustement, en particulier si la perte de validation recommence à augmenter vers la fin, comme elle semble le faire légèrement.

Occasionnelles, suggère que le modèle a maintenu de bonnes performances de généralisation sur l'ensemble de données de validation.

Accuracy (à droite)

- **Précision de l'entraînement** : La ligne bleue représente la précision de l'apprentissage. Elle commence par être plus basse et augmente rapidement, en particulier au cours des premières époques. Elle continue ensuite à augmenter plus progressivement et devient plus stable, atteignant environ 98 % à la 50e époque. Cela montre que le modèle apprend et améliore sa précision sur les données d'apprentissage au fil du temps.

- **Précision de validation** : La ligne orange représente la précision de validation. Elle commence à un niveau élevé et augmente au fil des époques, bien qu'elle soit plus fluctuante que la précision d'apprentissage. Malgré ces fluctuations, la précision de validation tend également à augmenter, atteignant environ 96 % à la 50e époque. Les fluctuations pourraient indiquer un certain surajustement, lorsque la performance du modèle sur les données de validation est moins cohérente que sur les données d'apprentissage.

Le modèle fonctionne bien, mais les fluctuations de la perte de validation et de la précision suggèrent que certaines techniques de régularisation pourraient contribuer à améliorer la généralisation et la stabilité.

III.12 Métrique de qualité d'image

Pour évaluer les performances, nous prenons en compte la matrice de confusion pour calculer nos paramètres tels que l'exactitude, la précision, le rappel, le score F1, etc.

Précision

La précision est utilisée pour indiquer le degré d'exactitude du résultat prédit.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

Rappel

Le rappel est utilisé pour indiquer dans quelle mesure un résultat positif est donné en entrée.

$$\text{Rappel} = \text{TP} / (\text{TP} + \text{FN})$$

Score F1

Score F1 est la moyenne harmonique entre la précision et le rappel.

$$\text{Score F1} = 2 \cdot \text{Precision} \cdot \text{Rappel} / (\text{Precision} + \text{Rappel})$$

Intersection moyenne sur Union (IoU moyenne)

Mesure l'intersection moyenne des unions entre le masque prédit et le masque réel sur toutes les images.

La métrique Intersection over Union (IoU), La méthode également connue sous le nom d'indice Jaccard, vise principalement à mesurer le taux de chevauchement entre le masque cible et notre sortie de prédiction. Le coefficient est étroitement lié à cette métrique.

Dice fréquemment employé comme indicateur de perte lors de l'entraînement.

$$IoU = TP / (TP + FP + FN)$$

- TP est le nombre de vrais positifs
- FP le nombre de faux positifs.
- TN est le nombre de vrais négatifs
- FN le nombre de faux négatifs.

Indicateur	la valeur
IoU moyenne	0.8134133
Score de précision	0.822
Score de rappel	0.780
Score F1	0.801

Tableau III.2 : Indicateur, la valeur

Les valeurs présentées reflètent une performance bonne et équilibrée du modèle dans l'identification des zones cibles dans les images médicales.

Un taux d'utilité élevé indique une bonne concordance entre les prédictions et les masques réels.

Une précision élevée indique que le modèle fait des prédictions correctes à un taux élevé. Le taux de récupération indique que le modèle peut manquer certains cas, mais que la performance globale reste bonne.

Le score F1 reflète un bon équilibre entre la précision et le rappel, ce qui signifie que le modèle est fiable pour les tâches pratiques.

III.13 Afficher les résultats

Une série d'images originales, de masques réels et les prédictions obtenues à partir du modèle ont été montrées.




Figure III.6 : Résultats de prédiction du modèle dans les images médicales

Les images présentées montrent un ensemble d'images d'échographie avec la segmentation correspondante et les prédictions générées par un algorithme d'apprentissage profond. Chaque ensemble est composé de trois images : L'image originale, le masque exact de la zone cible, et la prédiction faite par le modèle.

- 1. Image originale** : Montre les données médicales telles qu'elles ont été capturées par l'échographe. Ces images constituent la base du processus d'analyse et de segmentation.
- 2. Masque** : Représente la segmentation exacte de la zone cible dans l'image originale. Cette segmentation est utilisée comme critère de vérité de base dans le processus de formation et d'évaluation du modèle.
- 3. Prédiction** : Affiche les résultats du modèle qui a été entraîné à imiter la segmentation précise. La précision de la prédiction reflète la capacité du modèle à apprendre et à imiter la segmentation correcte.

La segmentation précise des images médicales joue un rôle essentiel dans le diagnostic des maladies et le suivi de l'évolution de l'état de santé. La capacité à identifier avec précision les zones cibles aide les cliniciens à déterminer les procédures de traitement appropriées et à évaluer leur efficacité.

L'un des défis de l'application de cette technologie est la nécessité de disposer de grandes quantités de données étiquetées avec précision pour entraîner les modèles. Cependant, il existe d'importantes possibilités de développer des algorithmes plus avancés qui améliorent les diagnostics et les traitements médicaux.

III.14 Conclusion

Le modèle UNet a montré une performance forte et équilibrée dans la segmentation d'images médicales, ce qui le rend approprié pour des applications pratiques dans les domaines du diagnostic médical. Ces résultats constituent une base solide pour le développement de modèles plus efficaces et plus précis à l'avenir, et renforcent l'utilisation des technologies intelligentes dans le domaine médical afin d'améliorer la précision du diagnostic et la rapidité du traitement.

Conclusion Général

Conclusion Générale

Ce travail traite les méthodes de segmentation d'images, ces techniques modernes basées sur l'apprentissage profond. Ou la segmentation est fondamentale pour le traitement des images numériques, car elle vise à séparer une image en régions homogènes ou à séparer des objets sur la base de critères tels que la couleur ou l'intensité.

Les méthodes traditionnelles de segmentation comprennent :

- La Segmentation basée sur le seuil : Elle repose sur l'attribution d'une certaine valeur pour séparer les régions.
- La segmentation basée sur les régions : Elle regroupe les pixels voisins présentant des caractéristiques similaires.
- Segmentation basée sur les contours : Identifie les bords qui séparent les différents objets et régions.
- Segmentation basée sur la classification : Comprend la classification supervisée et non supervisée pour organiser les pixels en groupes homogènes.

D'autre part, les techniques d'apprentissage profond, telles que les réseaux neuronaux convolutifs (CNN), offrent une précision et une efficacité accrues par rapport aux méthodes traditionnelles. Ces réseaux sont formés à l'aide d'énormes ensembles de données et leurs performances sont optimisées grâce à des techniques telles que l'optimisation incrémentale.

La segmentation des images est un processus essentiel qui améliore la précision de l'analyse et l'extraction des données importantes. L'efficacité de ce processus dépend du choix d'une méthode adaptée aux caractéristiques de l'image et aux objectifs spécifiques. Les techniques d'apprentissage profond offrent des possibilités avancées pour atteindre une grande précision, améliorant ainsi les applications pratiques dans des domaines tels que l'imagerie médicale, l'analyse d'images satellites et les véhicules autonomes.

Les résultats expérimentaux indiquent que les techniques d'apprentissage profond surpassent les méthodes traditionnelles en termes de performance et de précision. Les discussions portent sur l'évaluation de la précision et de l'efficacité de chaque méthode sur la base des critères tels que la précision, la sensibilité et la spécificité, et sur l'analyse des différences entre les méthodes traditionnelles et les techniques d'apprentissage profond.

Références

- [1] K. Aounallah, les approches de segmentation d'image par coopération régions-contours, 2010
- [2] S.Benfriha, A.Hamel. Segmentation d'image par Coopération région-contours. Université KasdiMerbah-Ouargla, 2016.
- [3] Qu'est-ce que la segmentation d'images ? - La revue IA
- [4] <https://www.ibm.com/fr-fr/topics/image-segmentation>
- [5] https://xphilipp.developpez.com/articles/segmentation/regions/?page=page_4
- [6] C.Houassine, segmentation d'images par une approche biomimétique hybride. Université universite m'hamed bougara- boumerdes. 2012.
- [7] https://fr.wikipedia.org/wiki/Filtre_de_Canny
- [8] Fares, W. A. (2013). Détection et suivi d'objets par vision fondés sur segmentation par contour actif basé région (Doctoral dissertation, Université Paul Sabatier-Toulouse III).
- [9] <https://openclassrooms.com/fr/courses/4525281-realisez-une-analyse-exploratoire-de-donnees/5291335-decouvrez-les-methodes-factorielles-et-la-classification-non-supervisee>.
- [10] Sage. (2021b, August 5). Qu'est-ce-que le Deep Learning ? - Sage Advice France. Sage Advice France.
- [11] Woo, P., & Woo, P. (2023, September 1). Comprendre le deep learning : ce sous-domaine de l'IA. LeDigitaliseur.
- [12] L, B. (2022, July 26). Deep Learning ou apprentissage profond : définition, concept. LEBIGDATA.FR.
- [13] Andre, D. (2023c, December 4). Qu'est-ce qu'un Réseau Neuronal Convolutif? - All About AI. All About AI.
- [14] Introduction aux réseaux neuronaux convolutifs (CNN) | 3 choses à savoir. (n.d.-b). MATLAB & Simulink.
- [15] Robert, J. (2024, January 31). Convolutional Neural Network : Tout ce qu'il y a à savoir. Formation Data Science | DataScientest.com.
- [16] Obam, Y. S. (2021, December 13). Comprendre les Réseaux de Neurones Convolutifs (CNN). Medium.
- [17] Robert, J. (2024b, January 31). Convolutional Neural Network : Tout ce qu'il y a à savoir. Formation Data Science | DataScientest.com.
- [18] Balaji, S. (2023, August 26). Binary Image classifier CNN using TensorFlow - Techiepedia - Medium. Medium.
- [19] www.kaggle.com/datasets

[20] *Le tutoriel Python*. (n.d.). Python Documentation.

[21] Zhang, E., Liu, L., & Huang, L. (2019c). Automatically delineating the calving front of Jakobshavn Isbræ from multitemporal TerraSAR-X images: a deep learning approach. *the Cryosphere*, 13(6), 1729–1741.