

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

**UNIVERSITE MOHAMED BOUDIAF - M'SILA**

**FACULTE DE Technologie**  
**DEPARTEMENT Electronique**



**FILIÈRE : Electronique**  
**OPTION : Electronique des Systèmes embarqués**

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

**Par :**

**Saadi Khaled Iben El Walid & Bendahi Khaled**

**THÈME**

**Segmentation D'Image Médicale Via Non  
superviser Réseau de neurones convolutif**

**Soutenu devant le jury composé de:**

Dr. ZERDOUMI Zohra	Université M <sup>ed</sup> Boudiaf –M'sila Président
Dr LALAOUI Lahouaoui	Université M <sup>ed</sup> Boudiaf –M'sila Rapporteur
Dr. KHALFA Ali.	Université M <sup>ed</sup> Boudiaf –M'sila Examineur

**Année universitaire : 2021 /2022**

# *Remerciements*

Nous remercions Dieu le tout puissant, qui nous a donné la force et la patience pour l'accomplissement de ce travail.

*Et la patience pour l'accomplissement de ce travail. Nous tenons à exprimer notre gratitude à monsieur LALAOUI pour son orientation, supervision et sa patience.*

*Le travail sous sa supervision a été une expérience de confiance. Nous remercions les enseignants du département d'électronique qui m'enseignée.*

*Enfin, Nous tenons à remercier tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.*

*Merci à tous et à toutes.*

## Dédicaces

*Je dédie ce travail aux êtres qui me sont les plus chers :  
A ma mère, source de sagesse. A l'âme de mon père que  
Dieu le place dans ses paradis. A mes très chères sœur  
Nouch et Amina. A mes très chère frère Lamjed et  
Abdelkader avec ses enfants. A ma femme **Khadîdja**,  
Et tous les membres de ma famille petits et grands avec  
ses enfants. Et **Hamza Djadar** le président de club  
ADSA-Djelfa A mon binôme **Khaled**, pour sa  
compréhension, et sa tolérance lors de la réalisation de  
notre projet.  
Et enfin a tous mes amis*

Khaled Iben El Walid

## Dédicaces

*Je tiens à dédier ce modeste travail en guise de remerciements et de gratitude.*

*À ma chère mère, pour ta présence, tes paroles et tes sacrifices ainsi que ton aide et ton soutien, de m'avoir accordé un environnement sain et agréable au quotidien.*

*À mes sœurs et mes frères, À mes plus chers amis  
À mes amis de promotion, je vous souhaite une  
bonne continuation tant dans votre vie  
personnelle que professionnelle.*

*Je tiens en fin à remercier chaque personne ayant  
contribué de près ou de loin à la réalisation de ce  
mémoire*

**Khaled**

**Sommaire**

<b>Introduction générale .....</b>	<b>1</b>
<b>Chapitre 1 Les notions de traitement d'image .....</b>	<b>3</b>
1.1 Introduction.....	3
1.2 définition d'image .....	4
1.3 Types d'image.....	4
1.3.1 Selon la représentation numérique.....	5
1.3.2 Selon la représentation des couleurs .....	5
1.3.2.1 Les modèles de couleur.....	6
1.3.2.2 Images en teintes (ou niveaux) de gris.....	7
1.3.2.3 Image à palettes ,image en 256 couleurs (8bits).....	7
1.3.2.4 Images 24 bits (ou « couleurs vraies »).....	8
1.4 Formats d'image .....	8
1.4.1 Précautions à prendre .....	10
1.5 Caractéristiques d'images.....	11
1.6 Traitement d'image .....	12
1.6.1 Système de traitement d'image .....	12
1.6.2 Les étapes de traitement d'image.....	12
1.6.2.1 Acquisition d'une image.....	13
1.7 Filtrage d'image .....	13
1.7.1 Filtres linéaires.....	13
1.7.2 FILTRE moyenneur (lissage).....	14
1.7.3 Filtre gaussien.....	14
1.7.4 Filtre rehausseur de contours.....	14
1.7.5 Filtres non linéaires.....	15
1.8 Segmentation des images.....	15
1.8.1 Principe de segmentation d'image.....	16
1.8.2 Segmentation de l'image en trois sous-étapes.....	16
1.9 Les applications du traitement d'images numériques.....	18
<b>Chapitre 2 Segmentation d'images médicales.....</b>	<b>19</b>
2.1 Introduction.....	19
2.2 Segmentation d'Image .....	20

2.3	But et Difficultés de la Segmentation .....	21
2.4	Les méthodes de segmentation.....	21
2.4.1	Segmentation basée sur les arêtes.....	21
2.4.2	Segmentation basée contour .....	23
2.4.3	La segmentation par division fusion .....	23
2.4.4	Segmentation basée clustering .....	23
2.4.5	Segmentation par seuillage .....	24
2.4.5.1	Seuillage multiniveaux.....	25
2.4.5.2	Seuillage local.....	28
2.4.5.3	Méthode par indice de similarité.....	30
2.4.6	Segmentation par région .....	30
2.5	Principe de segmentation .....	31
2.5.1	Balayage.....	31
2.6	Segmentation par Croissance de Région .....	32
2.7	Segmentation par Partage de Région .....	34
2.8	Conclusion .....	34

### **Chapitre3 Les Réseauxdneurones**

3.1	Introduction.....	35
3.2	Historique .....	35
3.3	Les Réseaux de neurones.....	36
3.4	Principe de Fonctionnement des réseaux de neurones.....	37
3.5	Les différents types de réseaux de neurones.....	38
1.5.1	Réseau de neurones récurrent – Recurrent Neural Network (RNN).....	38
1.5.2	Réseau de neurones convolutif – Convolution Neural Network (CNN).38Convolution Neural Network (CNN) .....	39
3.5.1	Le principe de la CNN.....	39
3.5.2	Les dimensions de la CNN.....	39
3.6	Les principaux composants du CNN .....	40
3.6.1	1D Convolutional layers.....	40
3.6.2	Pooling layers.....	41
3.6.3	Fully connected layers (FC).....	42
3.6.4	Dropout layers.....	43
3.6.5	Loss function.....	43
3.7	Architecture .....	44
3.8	Couche CNN.....	44

3.8.1	Couche de convolution(CONV).....	45
3.8.2	Couche de pooling (POOL).....	45
3.8.3	La couche de correction ReLU.....	47
3.8.4	3.9.4 Le flattening (ou mise à plat).....	47
	3.9.4.1 Quel est l'intérêt de cette étape ?	
3.9.5	La partie "fully connected" ou "dense" alias le réseau de neurones artificiels (perceptron multi-couches).....	47
	3.9.6 le padding.....	47
3.10	Paramètres des CNN.....	48
3.11	Avantages de CNN.....	48
3.12	Conclusion.....	49
<b>Chapitre4Implémentation .</b>		
4.1	Introduction.....	49
4.2	Présentation de l'application développée .....	50
	4.2.1Environnement de travail.....	50
4.3	Introduction à U-Net .....	50
4.4	L'architecture U-Net .....	52
	4.4.1 La base de données image.....	53
	4.4.2 Les résultats obtenus.....	53
4.5	Résultats des calculs .....	53
	4.5.1 La mesure de précision (Accuracy .....	56
4.6	Training on single CPU000 .....	56
4.7	Conclusion .....	57
<b>Conclusion générale.....</b>		<b>58</b>
<b>Bibliographie .....</b>		<b>60</b>

## Listedesfigures

Figure1.1 :Une image numérique 1.....	4
Figure1.2 : Image vectorielle .....	5
Figure1.3 Image matricielle .....	5

Figure1.4: Le spectre électromagnétique [1] .....	6
Figure1.5 : image en niveau de gris [2] .....	6
Figure1.6: image en 8bit .....	7
Figure1.7 : Image 24 bits aux couleurs vraies et son image segmentée seulement en Couleurs.[3] .....	8
Figure1.8 principe de traitement image .....	11
Figure1.9: Différents appareils de détection des images .....	13
Figure1.10: les étapes de traitement d'image .....	16
Figure2-1 Exemple de Segmentation d'image effectuée par des humains .....	20
Figure2-2 segmentation bas sur le contour .....	22
Figure2-3 : image de différent seuil .....	22
Figure2-4 Image originale .....	24
Figure2-5:(b) Seuillage à 110 .....	24
Figure2-6:(c) Seuillage à 128 .....	24
Figure2-7:(d) Seuillage après égalisation [7] .....	24
Figure2-8: Seuillage local .....	25
Figure2-9: les critères d'homogénéité d'une région .....	28
Figure2-10: 4 voisins diagonaux .....	30
Figure2-11: représentation méthode par indice de similarité .....	31
Figure 2-12 : représentation de la croissance de région...	
Figure2-13: .....	32
Figure2-14: les critères d'hétérogénéité d'une région .....	33
Figure3-1 Représentation du réseau de neurones humain .....	33
Figure3-2 Représentation du réseau de neurones artificiel .....	36
Figure3-3 exemple d'un filtre de convolution 1D .....	37
Figure3-4 Les fonctions D'activation .....	38
Figure3-5 Exemple sur le Maxpooling .....	41
Figure3-6 Représentation des fully-connected Layers .....	42
Figure3-7 Exemple sur le fonctionnement des Dropout Layers .....	43
Figure3-8 réseaux de neurone convolutif [11] .....	43
Figure3-9 Exemple de filtre de taille (3*3) .....	44
Figure3-10 Max poling .....	45

Figure3-11Average pooling.....	46
Figure3-12Allure de la fonction ReLU .....	46
Figure3-13Padding de 2 autour d'une image de taille 32×32 .....	47
Figure 4-1 :La page d'accueil de MATLAB R2020a.....	48
Figure 4-2 : l'architecture U-Net.....	52
Figure 4-3 :l'image résultats Vérité terrain,original image, CNNrésulte, K=1.....	53
Figure4-4 :l'image résultats Vérité terrain, original image,CNN, K=10.....	54
Figure4-5:: l'image résultats Vérité terrain, originalimage, Image segmentation par CNN résulte, K=20 .....	55
Figure 4-6 :Figure 4-6 : l'image résultats : Vérité terrain, image originale, Image segmentation par.....	55

## Listedestableaux

<i>Tableau1.1 : comparatif de différents formats d'images .....</i>	<i>9</i>
<i>Tableau1.2 :Classificationdestumeurssuivantl'AJCC .....</i>	<i>10</i>
<i>Tableau3.2:Résultats total des calculs ACC, QC.....</i>	<i>12</i>

# Chapitre I les notions de traitement d'image

## Introduction générale

Nous avons assisté ces dernières années à l'explosion de l'Informatique. L'augmentation continue de la puissance de calcul des ordinateurs a permis le développement du traitement d'images, qui est un sous domaine du traitement de signal, particulièrement gourmand en temps de calcul car nécessitant un très grand nombre d'opérations mathématiques, physiques et aussi informatiques. Traditionnellement, dans le domaine du traitement d'images, deux grandes voies se distinguaient : la synthèse d'images et l'analyse d'images. On ne fait plus de distinction entre les deux axes qui se rejoignent désormais. L'analyse d'images est le domaine qui nous préoccupe ici particulièrement, elle présente un intérêt dans quasiment tous les domaines où le problème de la recherche automatique d'informations dans des images s'avère un besoin. Donnons par exemple l'imagerie médicale.

L'imagerie médicale est un outil de diagnostic et de suivi primordial, et l'interprétation des données qu'elle peut fournir est un élément important du dossier patient.

Les méthodes automatiques de traitement et d'analyse d'images se sont récemment multipliées pour assister l'expert dans l'analyse qualitative et quantitative de ces images et faciliter leur interprétation. Ces méthodes doivent prendre en considération d'une part la quantité des données à analyser et d'autre part, la complexité structurelle des images médicales.

L'exploitation des images médicales nécessite un traitement de bas niveau tel que la segmentation qui est extrêmement compliquée. En effet, pour chaque organe (cerveau, cœur, etc. ), l'approche à adopter est différente : l'outil de segmentation doit donc pouvoir s'adapter à un organe particulier, suivant une modalité d'acquisition particulière (scanners, radiographie, Imagerie par Résonance Magnétique) et pour une séquence de données particulière.

L'objectif est la quantification de l'information, par exemple, la volumétrie : volume d'une tumeur dans le sein .C'est à ce niveau que la segmentation de l'image est utilisée.

La qualité de la segmentation, c'est à dire, la précision de la localisation et la non-confusion des régions ont un impact direct sur les performances de l'application.

Dans le cadre de ce mémoire, nous sommes intéressés au problème de segmentation d'images médicale. Ceci est réalisé grâce aux différents modèles des réseaux de neurones convolutifs (CNN), pour l'extraction automatique de l'information issue directement des

# Chapitre I les notions de traitement d'image

images d'entrée, au lieu d'une extraction manuelle, pour éviter les problèmes de sur apprentissage.

- ✓ Premier chapitre : dans ce chapitre nous parlerons quelques notions de base du domaine de traitement d'image numérique et la détection des anomalies dans ces images, filtrage, segmentation et leur application dans des différents domaines et en fin quelques exemples concrets de traitement d'images.
- ✓ Deuxième Chapitre : ce chapitre est dédié à la segmentation d'images médicales et les différentes techniques et approches de segmentation
- ✓ Troisième chapitre : état de l'art et étude conceptuelle. Ce chapitre sera consacré au réseau de neurones convolutifs et ses architectures, tout en évoquant les techniques de réduction du sur apprentissage
- ✓ Quatrième chapitre : Mise en œuvre du système et résultats. Nous exposerons dans ce chapitre, les outils utilisés ainsi que l'environnement de travail. Nous présenterons aussi les résultats obtenus lors de la phase d'expérimentation, pour la classification et la détection des tumeurs malignes.

# Chapitre I les notions de traitement d'image

## 1.1 Introduction

Le traitement d'images désigne une discipline des mathématiques appliquées qui étudie les images numériques et leurs transformations, dans le but d'améliorer leur qualité ou d'en extraire de l'information. Il s'agit donc d'un sous-ensemble du traitement du signal dédié aux images et aux données dérivées comme la vidéo (par opposition aux parties du traitement du signal consacrées à d'autres types de données : son et autres signaux monodimensionnels notamment), tout en opérant dans le domaine numérique (par opposition aux techniques analogiques de traitement du signal, comme la photographie ou la télévision traditionnelles).

Dans ce chapitre nous parlerons quelques notions de base du domaine de traitement d'image numérique tels que : la définition d'image, les types d'image, formats d'images, caractéristiques d'image, système de traitement d'image, analyse élémentaire, filtrage, segmentation et leur application dans des différents domaines et en fin quelques exemples concrets de traitement d'images.

## 1.2 Définition d'image

L'image est une représentation d'une personne ou d'un objet par la peinture, la sculpture, le dessin, la photographie, le film ou divers procédés électroniques de visualisation. C'est aussi un ensemble de structure d'informations qui, après affichage sur l'écran, a une signification pour l'œil humain.

Chaque point de l'image peut être représentée par une fonction  $f(x', y', \lambda, t)$ , où  $x', y'$  sont les coordonnées spatiales d'un point de l'objet décrit dans un système de coordonnées cartésiennes,  $\lambda$  est la longueur d'onde rayonnée par le point et  $t$  le temps. En réalité, à chaque instant, on ne voit qu'une image fixe et l'image peut être simplifiée sous la forme  $f(x', y', \lambda)$ .

Une image est caractérisée par :

- **Définition :** C'est le nombre de point (pixel) constituant une image, exprimée en points ou en pixels.
- **Taille ou poids :** c'est l'espace qu'occupe une image sur un support, exprimé en octet
- **Résolution :** c'est le nombre de point ou de pixel par unité de surface, exprimée en pixel par pouce (ppp)

# Chapitre I les notions de traitement d'image

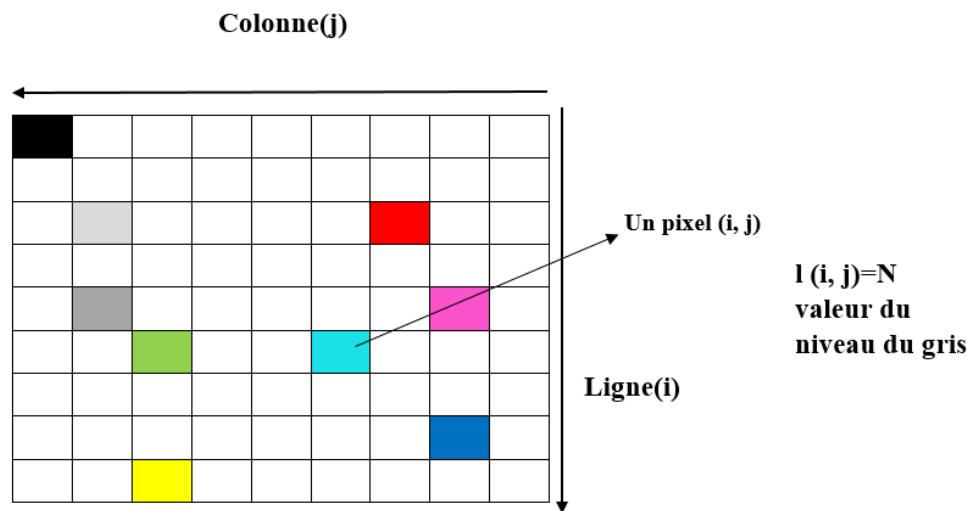


Figure 1.1 : Une image numérique I

## 1.3 Types d'images

On peut classifier les images numériques selon deux critères :

### 1.3.1 Selon la représentation numérique :

Ils existent deux types :

#### a) Images matricielles (ou images bitmap)

Elle est composée comme son nom l'indique d'une matrice (tableau) de points à plusieurs dimensions, chaque dimension représentant une dimension spatiale (hauteur, largeur, profondeur), temporelle (durée) ou autre (par exemple, un niveau de résolution).

#### b) Images vectorielles

Le principe est de représenter les données de l'image par des formules géométriques qui vont pouvoir être décrites d'un point de vue mathématique. Cela signifie qu'au lieu de mémoriser une mosaïque de points élémentaires, on stocke la succession d'opérations conduisant au tracé. Par exemple, un dessin peut être mémorisé par l'ordinateur comme « une droite tracée entre les points (x1, y1) et (x2, y2) », puis « un cercle tracé de centre (x3, y3) et de rayon 30 de couleur rouge ».

L'avantage de ce type d'image est la possibilité de l'agrandir indéfiniment sans perdre la qualité initiale, ainsi qu'un faible encombrement. L'usage de prédilection de ce type d'images concerne les schémas qu'il est possible de générer avec certains logiciels de DAO (Dessin Assisté par Ordinateur).

# Chapitre I les notions de traitement d'image

Ce type d'images est aussi utilisé pour les animations Flash, utilisées sur Internet pour la création de bannières publicitaires, l'introduction de sites web, voire des sites web complet.



Figure 1.2 : Image vectorielle



Figure 1.3 : Image matricielle

## 1.3.2 Selon la représentation des couleurs

Il existe plusieurs modes de codage informatique des couleurs, le plus utilisé pour le maniement des images est l'espace colorimétrique Rouge, Vert, Bleu (RVB ou RGB - Red green Blue).

### 1.3.2.1 Les modèles de couleur

La couleur est l'une des composantes principales pour la description et l'analyse des images couleurs dans le domaine de la recherche d'images par le contenu. Comme nous le savons, les couleurs perceptibles par l'œil humain représente une petite gamme de l'ensemble du spectre électromagnétique qui représente tous les rayons, depuis les rayons cosmiques et les rayons X jusqu'aux ondes électriques (Figure 1.3).

Comme le démontre la figure 1 du spectre électromagnétique, les couleurs visibles par l'œil humain s'étendent entre les longueurs d'ondes allant de 4000 à 7000 angströms, représentant respectivement les couleurs : violet et rouge et toutes les couleurs entre les deux. Toutes les autres ondes s'étendant des rayons cosmiques des étoiles jusqu'aux ondes FM de nos radios ne peuvent pas être perçues par l'œil humain. Cette petite gamme du spectre est l'espace de couleur perceptible par l'œil humain.

# Chapitre I les notions de traitement d'image




Figure 1.4 : Le spectre électromagnétique [1]

On distingue généralement les différents types d'images suivants :

## 1.3.2.2 Images en teintes (ou niveaux) de gris

Une image en niveau de gris est une image composée de points gris plus ou moins foncés. En général on sauve les images à 16 niveaux de gris ou à 256 niveaux.

Ce procédé est fréquemment utilisé pour reproduire des photos en noir et blanc ou du texte dans certaines conditions (avec utilisation d'un filtre pour adoucir les contours afin d'obtenir des caractères plus lisses).



Figure 1.5 : image en niveau de gris [2]

# Chapitre I les notions de traitement d'image

## 1.3.2.3 Images à palettes, images en 256 couleurs (8 bits)

Pour réduire la place occupée par l'information de couleur, on utilise une palette de couleurs « attachée » à l'image. On parle alors de couleurs indexées : la valeur associée à un pixel ne véhicule plus la couleur effective du pixel, mais renvoie à l'entrée correspondant à cette valeur dans une table (ou palette) de couleurs appelée look-up table ou LUT en anglais, dans laquelle on dispose de la représentation complète de la couleur considérée. Selon le nombre de couleurs présentes dans l'image, on peut ainsi gagner une place non négligeable : on considère en pratique que 256 couleurs parmi les 16 millions de couleurs 24 bits sont suffisantes. Pour les coder, on aura donc une palette occupant 24 bits x 256 entrées, soit 3 x 256 octets, et les pixels de l'image seront associés à des index codés sur un octet. L'occupation d'une telle image est donc de 1 octet par pixel plus la LUT, ce qui représente un peu plus du tiers de la place occupée par une image en couleurs 24 bits (plus l'image contient de pixels, plus le gain de place est important, la limite étant le tiers de la place occupée par l'image en couleurs vraies).



**Figure 1.6 :** image en 8bit

## 1.3.2.4 Images 24 bits (ou « couleurs vraies »)

Il s'agit d'une appellation trompeuse car le monde numérique (fini, limité) ne peut pas rendre compte intégralement de la réalité (infinie). Le codage de la couleur est réalisé sur trois octets, chaque octet représentant la valeur d'une composante couleur par un entier de 0 à 255. Ces trois valeurs codent généralement la couleur dans l'espace RVB.

# Chapitre I les notions de traitement d'image



**Figure 1.7 :** Image 24 bits aux couleurs vraies et son image segmentée seulement en 12 Couleurs.[3]

Le nombre de couleurs différentes pouvant être ainsi représenté est de  $256 \times 256 \times 256$  possibilités, soit près de 16 millions de couleurs. On considère commodément que ce système permet une restitution exacte des couleurs, c'est pourquoi on parle de « couleurs vraies ». Les images bitmap basées sur cette représentation peuvent rapidement occuper un espace de stockage considérable, chaque pixel nécessitant trois octets pour coder sa couleur.

## 1.4. Formats d'image

Un format d'image est une représentation informatique de l'image, associée à des informations sur la façon dont l'image est codée et fournissant éventuellement des indications sur la manière de la décoder et de la manipuler.

La plupart des formats sont composés d'un en-tête contenant des attributs (dimensions de l'image, type de codage, LUT, etc.), suivi des données (l'image proprement dite). La structuration des attributs et des données diffère pour chaque format d'image. De plus, les formats actuels intègrent souvent une zone de métadonnées (Meta data en anglais) servant à préciser les informations concernant l'image comme :

La date, l'heure et le lieu de la prise de vue.

Les caractéristiques physiques de la photographie (sensibilité ISO, vitesse d'obturation, usage du flash...) Ces métadonnées sont par exemple largement utilisées dans le format Exif (extension du format JPEG), qui est le format le plus utilisé dans les appareils photo numériques.

### 1.4.1 Précautions à prendre

Quelques précautions à prendre concernant les formats d'images :

## Chapitre I les notions de traitement d'image

- ❖ les formats dits « propriétaires », peuvent différer selon le logiciel qui les manipule. De plus, leur pérennité n'est pas garantie : réaliser de nouveaux programmes pour les lire peut s'avérer difficile (surtout si leurs spécifications n'ont pas été rendues publiques), cela peut même s'avérer illégal si les algorithmes utilisés sont protégés par des brevets
- ❖ il faut prêter attention aux différentes versions que peut recouvrir un format particulier, notamment pour le format TIFF qui varie selon les versions ; certaines d'entre elles ne sont pas reconnues par certains logiciels.

	Type (matriciel/ vectoriel)	Compression des données	Nombre de couleurs supporté es	Affichage progressif	Animation	Transparence
<b>JPEG</b>	matriciel	Oui, réglable (avec perte)	16 millions	oui	Non	Non
<b>JPEG2000</b>	matriciel	Oui, avec ou sans perte	32 millions	oui	Non	non
<b>GIF</b>	matriciel	Oui, Sans perte	256 maxi (palette)	oui	oui	oui
<b>PNG</b>	matriciel	Oui, Sans perte	Palettisé (256 couleurs ou moins) ou 16 millions	oui	oui	oui(par alpha)
<b>TIFF</b>	matriciel	Compression ou pas avec ou sans pertes	de monochrome à 16 millions	oui	non	oui(par alpha)
<b>SVG</b>	Vectoriel	compression possible	16 millions	ne s'applique pas *	oui	oui(par nature)

**Tableau 1.1** comparatif de différents formats d'images

# Chapitre I les notions de traitement d'image

## 1.5 Caractéristiques d'images

L'image est un ensemble structuré d'informations caractérisé par les paramètres suivants :

### ➤ **Pixel**

Le pixel, abrégé px, est une unité de surface permettant de définir la base d'une image numérique. Son nom provient de la locution anglaise Picture élément, qui signifie, « élément d'image » ou « point élémentaire ».

### ➤ **La texture**

Une texture est une région dans une image numérique qui a des caractéristiques homogènes. Ces caractéristiques sont par exemple un motif basique qui se répète, ou des caractéristiques fréquentielles. Une texture est composée de texels, l'équivalent des pixels.

### ➤ **Dimension**

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image.

### ➤ **Résolution**

C'est la clarté ou la finesse de détails atteinte par un moniteur ou une imprimante dans la production d'images. Sur les moniteurs d'ordinateurs, la résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre). On utilise aussi le mot résolution pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur ; plus grand est ce nombre, meilleure est la résolution.

### ➤ **Bruit**

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur.

### ➤ **Histogramme**

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image, on modifie souvent l'histogramme correspondant. Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de

# Chapitre I les notions de traitement d'image

gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. Il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'image) en introduisant quelques modifications, pour pouvoir extraire les informations utiles de celle-ci.

## ➤ Contours et textures

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes.

## ➤ Luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, pour un observateur lointain, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet.


C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. Si  $L_1$  et  $L_2$  sont les degrés de luminosité respectivement de deux zones voisines  $A_1$  et  $A_2$  d'une image, le contraste  $C$  est défini par le rapport :

$$C = \frac{L_1 - L_2}{L_1 + L_2}$$

## 1.6 Traitement d'image

Le traitement d'images désigne une discipline de l'informatique et des mathématiques appliquées qui étudie les images numériques et leurs transformations, dans le but d'améliorer leur qualité ou d'en extraire de l'information.

Il s'agit d'un sous-ensemble du traitement du signal dédié aux images et aux données dérivées comme la vidéo, tout en opérant dans le domaine numérique



# Chapitre I les notions de traitement d'image

**Figure 1.8** : principe de traitement image

## 1.6.1 Système de traitement d'image

Dans le contexte de la vision artificielle, le traitement d'images se place après les étapes d'acquisition et de numérisation, assurant les transformations d'images et la partie de calcul permettant d'aller vers une interprétation des images traitées. Cette phase d'interprétation est d'ailleurs de plus en plus intégrée dans le traitement d'images, en faisant appel notamment à l'intelligence artificielle pour manipuler des connaissances, principalement sur les informations dont on dispose à propos de ce que représentent les images traitées (connaissance du domaine).

## 1.6.2 Les étapes de traitement d'image

On peut résumer le traitement d'image en quatre étapes principales :

### 1.6.2.1 Acquisition d'une image

L'acquisition d'images est une mesure spatiale d'une interaction entre une onde et de la matière. L'onde est émise par une source et reçue par un capteur. Par exemple dans le cas de l'échographie, l'ultrason, une onde acoustique, est émis et reçue par la sonde. L'interaction est la réflexion de l'ultrason sur la structure du corps.

Dans le cas d'onde électromagnétique, la photographie utilise le spectre visible c'est-à-dire qui est visible pour l'œil humain. Il y a des applications sur l'ensemble du spectre électromagnétique, des rayons gamma jusqu'aux ondes radio. Ainsi, les images acquises par rayons X ou par rayons gamma sont surtout utilisées en imagerie médicale et en astronomie. En médecine, on utilise des imageurs IRM, TEP, scanner X, échographie Doppler, échographie, scintigraphie, tomographie.

Les deux caractéristiques importantes de la mesure spatiale est la taille du plus petit élément (pixel), mais aussi l'inter corrélation de deux éléments voisins : plus cette inter corrélation est faible, meilleure est l'image.

Pour l'acquisition d'une image on utilise des capteurs selon d'application désirée :

- Application : satellite
- Application avec grande précision : camera CCD
- Application (précisions non exagéré) : webCam

# Chapitre I les notions de traitement d'image



**Figure 1.9 :** Différents appareils de détection des images

Pour que ces images puissent être traitées par des systèmes informatiques.

Problème acquisition :

- faible luminosité
- changement de lumière (jour-nuit)
- ombre
- Changement de couleur
- camera en mouvement
- arrière-plan complexe

## 1.7 Filtrage d'image

On peut scinder les filtres en deux grandes catégories :

### 1.7.1 Filtres linéaires

Les premières et les plus simples méthodes de filtrage sont basées sur le filtrage linéaire, chacun de ses opérateurs est caractérisé par sa réponse impulsionnelle  $h(x, y)$ , l'expression qui relie les entrées avec les sorties est donnée par la relation suivante :  $S(i, j) = \sum_u \sum_v (E(i-u, j-v) \cdot h(i-u, j-v)) = h(i, j) * E(i, j)$ . Où :  $u, v$  varient de moins l'infini à plus l'infini. Le filtrage linéaire est un produit de convolution c à d une combinaison linéaire du voisinage du pixel concerné. Les différents types des filtres linéaires sont :

### 1.7.2 FILTRE moyennneur (lissage)

L'intensité du pixel considéré est remplacée par la moyenne des pixels de son voisinage, la taille de la zone (fenêtre) entourant le pixel est un paramètre important, plus cette dimension

# Chapitre I les notions de traitement d'image

est grande, plus Sa sensibilité au bruit diminue, et le lissage devient important (le flou s'accroît). Le filtre moyenneur est un filtre passe-bas c à d qu'il laisse passer les basses fréquences (les faibles changements d'intensité de l'image) et atténue les hautes fréquences (variations rapides). [4]

1/9X	1	1	1
	1	1	1
	1	1	1

**Masque de filtre**

## 1.7.3 Filtre gaussien

L'intérêt de ce filtre est que l'on contrôle facilement le degré de filtrage à travers le paramètre  $\sigma$ . Le filtre gaussien donne plus d'importance aux pixels proches du pixel central, et diminue cette importance au fur et à mesure que l'on s'éloigne de celui-ci, il a les mêmes inconvénients que le filtre moyenneur c à d il dégrade les contours. [4] La discrétisation de ce filtre pour un  $\sigma$  égale à 0.6 donne le masque suivant :

\*

1	2	1
2	4	2
1	2	1

**Masque de filtre**

## 1.7.4 Filtre rehausseur de CONTOURS

C'est un filtre passe haut c à d il met en évidence les changements rapides de l'intensité de l'image (les hautes fréquences) et laisse les zones uniformes inchangées (basses fréquences). [4]

-1	-1	-1
-1	9	-1
-1	-1	-1

**Masque de filtre**

## 1.7.5 Filtres non linéaires

Ils sont conçus pour régler les problèmes des filtres linéaires, sur tout pour ce qui concerne la mauvaise conservation des contours. Leur principe est le même que celui des filtres linéaires,

# Chapitre I les notions de traitement d'image

il s'agit toujours de remplacer la valeur de chaque pixel par la valeur d'une fonction calculée dans son voisinage, la seule différence c'est que cette fonction n'est plus linéaire mais une fonction quelconque (elle peut inclure des opérateurs de comparaisons).

## 1.8 Segmentation des images

La segmentation d'image est une opération de traitement d'images qui a pour but de rassembler des pixels entre eux suivant des critères prédéfinis. Les pixels sont ainsi regroupés en régions, qui constituent un pavage ou une partition de l'image. Il peut s'agir par exemple de séparer les objets du fond. Si le nombre de classes est égal à deux, elle est appelée aussi binarisation. Si l'homme sait naturellement séparer des objets dans une image c'est grâce à des connaissances de haut niveau. Mettre au point des algorithmes de segmentation de haut niveau est encore un des thèmes de recherche les plus courants en traitement d'images. La segmentation est une étape primordiale en traitement d'image. À ce jour, il existe de nombreuses méthodes de segmentation, que l'on peut regrouper en quatre principales classes :

- ✚ Segmentation fondée sur les régions (en anglais : region-based segmentation). On y trouve par exemple : la croissance de région (en anglais : region-growing), décomposition/fusion (en anglais : split and merge).
- ✚ Segmentation fondée sur les contours (en anglais : edge-based segmentation).
- ✚ Segmentation fondée sur classification ou le seuillage des pixels en fonction de leur intensité (en anglais : classification ou thresholding).
- ✚ Segmentation fondée sur la coopération entre les trois premières segmentations.

### 1.8.1 Principe de segmentation d'image

L'analyse d'images a pour but l'extraction de l'information caractéristique contenue dans une image. Le résultat d'une telle analyse s'appelle très souvent la description structurelle. Celle-ci peut prendre la forme d'une image ou de toute structure de données permettant une description des entités contenues dans l'image. Par opposition avec la phase d'interprétation, l'analyse tente, dans la mesure du possible, de ne pas prendre en compte le contexte (i.e. l'application). Essentiellement, l'analyse de l'image fait appel à la segmentation où l'on va tenter d'associer à chaque pixel de l'image un label en s'appuyant sur l'information portée (niveaux de gris ou couleur), sa distribution spatiale sur le support image, des modèles simples (le plus souvent des modèles géométriques).


# Chapitre I les notions de traitement d'image

La segmentation d'images ainsi définie est un domaine vaste où l'on retrouve de très nombreuses approches. Toutes ces approches visent à l'extraction des indices visuels. Après de nombreuses années passées à rechercher la méthode optimale, les chercheurs ont compris que la segmentation idéale n'existait pas. On peut même montrer que le problème de la segmentation est le plus souvent un problème mal posé. Etant donnée une image, il existe toujours plusieurs segmentations possibles. Une bonne méthode de segmentation sera donc celle qui permettra d'arriver à une bonne interprétation. Elle devra donc avoir simplifié l'image sans pour autant en avoir trop réduit le contenu. Entre autres, elle devra éviter les choix irréversibles. L'avenir de la segmentation est dans le pilotage aval par l'applicatif.

## 1.8.2 Segmentation de l'image en trois sous-étapes

Nous commencerons par voir le processus de segmentation de façon détaillée en passant par les trois (ou quatre) sous-étapes qui sont :

- le lissage de l'image initiale
- la segmentation de cette image lissée
- la fusion des plus petits segments avec les grands segments voisins les plus similaires (facultatif)
- la vectorisation de la segmentation.[5]



**Acquisition**

**Filtrage**

**segmentation**

**Figure 1.10** : les étapes de traitement d'image

## 1.9 Les applications du traitement d'images numériques

Le traitement d'images numériques trouve différents usages dans le monde réel.

- ❖ **Les médias sociaux :**

# Chapitre I les notions de traitement d'image

Des techniques de traitement d'images numériques telles que le filtrage en traitement d'image, sont appliquées pour l'amélioration et l'embellissement des images sur les médias sociaux.

## ❖ **L'imagerie médicale :**

Les techniques de traitement d'images numériques sont appliquées aux différents types d'imageries médicales telles que l'imagerie aux rayons X, les scanners, ...

En améliorant la qualité des images numériques issues de l'imagerie médicale, le traitement d'image numérique permet d'effectuer des diagnostics plus précis [6]

## ❖ **Contrôle de présence/absence :**

Sur des chaînes de production, on vérifie en bout de chaîne avec une caméra vidéo la présence d'une pièce dans un ensemble plus complexe. Pour cela, bien souvent il suffit de faire un simple seuillage dans une région spécifique.

## ❖ **Contrôle du niveau de maturation des fruits sur une chaîne de conditionnement :**

Il s'agit de reconnaître à la couleur et à la texture du fruit son degré de maturité et donc la catégorie sous laquelle il sera emballé puis vendu.

## ❖ **Construction et correction de cartes géographiques d'après des images satellites ou des images aériennes :**

On recale d'après des informations topographiques les images reçues, puis on les met sur la carte en correspondance avec les informations trouvées dans l'image : voies de communication, voies et plans d'eau, parcelles agricoles.

## ❖ **Surveillance et évaluation de la production agricole :**

Il est possible de déterminer le degré de maturation des cultures, la quantité d'eau nécessaire pour l'irrigation, le rendement moyen... On peut ainsi établir des prévisions à large échelle de la récolte à venir.

## ❖ **Reconnaissance de l'écriture :**

La reconnaissance de l'écriture manuscrite progresse de jour en jour. Elle est suffisamment opérationnelle pour que la majorité des adresses, même manuscrites, soient reconnues automatiquement sur le courrier postal.

## ❖ **Recherche d'image par le contenu :**

L'objectif de cette technique est de rechercher, parmi une base de données d'images, les images similaires à une image exemple, ou ayant certaines caractéristiques, par exemple rechercher toutes les images comportant un vélo.

# Chapitre I les notions de traitement d'image

## 1.10. Conclusion

En résulte que la manipulation, le stockage et la représentation de ces données se heurtent à certaines limitations. Grâce au traitement d'image, ces contraintes sont levées ou contournées. En effet, ce domaine cherche à détecter la présence de certaines formes, certains contours ou certaines textures d'un modèle connu, c'est le problème de la détection. Un autre aspect de traitement d'image concerne l'analyse et la compréhension de l'image dans le but d'en extraire des informations utiles. Il cherche aussi parfois à comprimer l'image, afin de gagner en vitesse lors de la transmission de l'information, et en capacité de stockage, tout en dégradant le moins possible les images considérées. Dans un CBIR il est mieux de faire un prétraitement avant de passer à l'indexation des images de base et ensuite la recherche d'image par contenu pour éliminer le bruit présent dans ces images.


### 2.1 Introduction

L'une des étapes critiques du traitement d'images est la segmentation, celle-ci consiste à localiser dans une image les régions (ensembles de pixels) appartenant à une même structure (objets ou scène imagés). Si l'homme sait naturellement séparer des objets dans une image c'est grâce à des connaissances de haut niveau (compréhension des objets et de la scène). Mettre au point des algorithmes de segmentation de haut niveau (chaque région est un objet sémantique) est encore un des thèmes de recherche les plus courants en traitement d'images. La segmentation est à la base de nombreuses applications tant en vision industrielle, qu'en imagerie médicale. De nombreuses recherches ont eu lieu sur les méthodes de segmentation. Il en résulte un très grand nombre de méthodes dont la comparaison, soit en termes de structure soit en termes de performance, est très difficile

Ce chapitre est consacré à la segmentation d'images médicales. Nous aborderons d'abord quelques notions fondamentales relatives à la segmentation d'images, nous verrons par la suite les différentes techniques et approches de segmentation figurant en littérature. Nous présenterons enfin le principe de notre approche de segmentation

### 2.2 Segmentation d'Image

En vision par ordinateur, la segmentation d'image est le processus de partitionner une image numérique en plusieurs segments ou régions homogènes (ensembles de pixels, également appelés super-pixels). Le but de la segmentation est de simplifier et / ou changer la représentation d'une image en quelque chose de plus significatif et plus facile à analyser. La segmentation est généralement utilisée pour localiser des objets et des limites dans les images. Plus précisément, la segmentation d'image est le processus d'attribution d'une étiquette à chaque pixel d'une image telle que les pixels avec la même étiquette partagent certaines caractéristiques. Segmenter une image signifie donc la diviser en "régions homogènes", selon un ou plusieurs attributs donnés (niveau de gris, texture, couleur, etc). On appelle "bords" ou "contours" de l'image les frontières entre ces régions. La notion de bonne segmentation/bonne détection de contours dépend fortement du type d'image à traiter et des applications envisagées



**Figure 2.1 :** Exemple de Segmentation d'image effectuée par des humains

. Il existe plusieurs méthodes pour effectuer la segmentation :

- Segmentation basée sur les pixels
- Segmentation par région
- Segmentation basée sur les arêtes

### 2.3 Buts et Difficultés de la Segmentation

- Le but de la segmentation est de partitionner une image en régions (par exemple, séparer les objets de l'arrière-plan)
- Les résultats de la segmentation sont très importants pour déterminer le succès ou échec éventuel de l'analyse d'image
- La segmentation est un problème très difficile en général

### 2.4 Les méthodes de segmentation

#### 2.4.1 Segmentation basée sur les arêtes

La segmentation basée sur les arêtes contient 2 étapes :

- 1) Détection des contours : dans la détection des contours, nous devons trouver les pixels qui sont des pixels de contour d'un objet. Il existe de nombreuses méthodes de détection d'objets telles que l'opérateur Sobel, l'opérateur Laplace, Canny, etc.
  - 2) Liaison des bords : dans cette étape, nous essayons d'affiner la détection des bords en reliant les bords adjacents et en les combinant pour former l'objet entier. La liaison de bord peut être effectuée à l'aide de l'une des deux méthodes ci-dessous :
    - **Traitement local** : Dans cette méthode, nous avons utilisé le gradient et la direction pour relier les bords du voisinage. Si deux arêtes ont un vecteur de direction similaire, elles peuvent être liées.
    - **Traitement global** : Cette méthode peut être effectuée à l'aide de la transformation HOG
- **Avantage**

Cette approche est similaire à la façon dont le cerveau humain aborde la tâche de segmentation.

Fonctionne bien dans les images avec un bon contraste entre l'objet et l'arrière-plan.

➤ **Limites**

Ne fonctionne pas bien sur les images avec des transitions douces et un faible contraste.

Sensible au bruit.

La liaison de bord robuste n'est pas triviale et facile à réaliser.

#### 2.4.2 Segmentation basée contour

La segmentation par contour consiste à repérer les contours d'une image. De ces contours, nous pourrions, par la suite, définir les différents objets qui composent l'image.

La détection des contours consiste à repérer les points d'une image qui correspondent à un changement brutal de l'intensité lumineuse.



**Figure 2.2 :** segmentation bas sur le contour

Pour réaliser cette opération, on définit un seuil qui nous permettra de dire à quelle valeur de changement d'intensité, il faut considérer le pixel comme un point de contour.

La définition de ce seuil est crucial car si on le choisit trop petit, des faux contours risquent d'apparaître sur l'image et si on le choisit trop grand, certains contours présenteront des trous.

Il existe néanmoins plusieurs algorithmes pour trouver le seuil idéal qui utilisent différents détecteurs de contours. Parmi ces contours, on retrouve les filtres de Sobel, Roberts et Canny.



*Image avec seuil trop bas*

*Image avec seuil plutôt correct*

*Image avec seuil trop haut*

**Figure 2.3 :** image de différent seuil

### 2.4.3 La segmentation par division fusion

Cette méthode est caractérisée par la division au préalable de l'image en régions homogènes disjointes qui respectent des critères globaux. Puis elle consiste à fusionner des régions adjacentes qui vérifient des critères locaux (exemple le critère d'homogénéité colorimétrique).

Nous détaillons trois structures de données permettant d'effectuer cette approche :

1. Le tétra-arbre
2. Le diagramme de Voronoï
3. Le graphe d'adjacence des régions

### 2.4.4 Segmentation basée clustering

Les techniques de clustering [Jain et al., 1999] sont des méthodes courantes en segmentation d'image et peuvent être divisées en deux catégories à savoir les algorithmes de partition et ceux hiérarchiques. La principale déférence est que les méthodes hiérarchiques produisent plusieurs

### 2.4.5 Segmentation par seuillage

La segmentation par seuillage est très semblable à la quantification d'image. Cette opération remplace un à un, chaque pixel en lui attribuant une valeur selon un seuil donné.

On peut, par exemple, avoir la transformation monochrome d'une image noir et blanc, en attribuant la valeur 255 à tous les pixels dont le niveau de gris est supérieur à 128 et 0 à tous ceux qui sont inférieurs.




Figure 2.4 : (a) Image originale




Figure 2.5: (b) Seuillage à 110




Figure 2.6: (c) Seuillage à 128




Figure 2.7 : (d) Seuillage après égalisation[7]

### 2.4.5.1 Seuillage multiniveaux

revient à trouver  $n$  seuils optimaux  $\mu_1 < \mu_2 < \dots < \mu_n$  dans  $h$ , i.e. à segmenter  $h$  en  $(n + 1)$  parties distinctes,  $i = \overline{1, \dots, n}$ .

L'image segmentée est alors :

$$I_{\text{segmentée}} = \bigcup_i R_i \text{ avec } (R) = \text{moyenne}(I(p)) \text{ où } \mu_i < I(p) < \mu_{i+1}$$

Ces méthodes supposent  $n$  connu ou pas, méthodes statistiques (mélange de gaussiennes.), etc. Ces méthodes sont globales : elles n'utilisent pas l'information spatiale sur les pixels.

### 2.4.5.2 Seuillage local


D'autres méthodes font un seuillage local, on calcule un seuil optimal ( $\theta$ ) à partir des caractéristiques locales de l'image  $I(p)$ .

- Méthodes locales  $\rightarrow$  Segmentation par transformation de régions

Le but de la Segmentation en Régions va être de regrouper entre eux les pixels d'une image vis à vis d'un critère d'homogénéité  $H$  et qui peut s'exprimer de la manière suivante : La segmentation d'une image  $I$  par rapport au critère  $H$  est une partition de l'image  $I$  en régions homogènes  $R_1, \dots, R_n$  telles que :

$$\bullet \forall i, j (R_i \cap R_j) \neq \emptyset \bullet \forall i, R_i \neq \emptyset \bullet \cup_i R_i = I$$

$\rightarrow$  Approche fondée sur un partitionnement Le traitement consiste à créer une partition de l'image  $I$  en sous-ensembles de pixels connexes  $R_i$  appelés régions



**Figure 2.8 :**Seuillage local

Les algorithmes de segmentation en régions sont généralement composés de plusieurs étapes successives. En effet, il est très difficile, voire quasiment impossible, de regrouper correctement les pixels pour former des régions en une seule procédure, car les régions sont généralement homogènes au centre et le sont de moins en moins plus on s'en éloigne. L'idée est de partir des zones homogènes puis de relâcher progressivement les contraintes. Ceci nous

amène à regrouper des pixels entre eux en un premier temps, puis des régions ensuite, ce qui ne peut pas se faire avec le même algorithme.

### ✚ Différentes Méthodes

La segmentation initiale peut être prise de deux manières différentes, ainsi qu'à partir d'une combinaison de ces deux manières :

- 1) **Méthode de Partage de régions** : à partir de l'image entière, et en la découpant récursivement jusqu'à obtenir des régions initiales suffisamment homogènes (algorithme de Découpage ou Split)
  
- 2) **Méthode de croissance de Régions** : à partir des pixels de l'image, que l'on regroupe ou fusionne les uns aux autres (algorithme de Fusion ou Merge)
  
- 3) **Méthode mixte** : à partir d'un regroupement quelconque, en utilisant successivement le découpage, puis la fusion. Une telle procédure est intéressante, lorsque l'on dispose d'une segmentation proche, ce qui est le cas lorsque l'on segmente une séquence d'images, où l'on dispose des résultats de la segmentation de l'image précédente pour segmenter l'image courante.

### ✚ Contexte

- Le problème de segmentation par régions est mal posé car il n'existe pas de segmentation idéale
- Le choix d'une méthode est lié : } à la nature des images (éclairage, texture, ...) } à la forme des primitives que l'on veut extraire ultérieurement des régions détectées } aux éventuelles contraintes de temps

### ✚ Notion de prédicat d'homogénéité

- Un prédicat est une proposition logique dont la valeur dépend de son argument
- $R_k$  est homogène si et seulement si  $P(R_k)$  est vraie avec :
- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $P$ , un prédicat définissant l'homogénéité d'une région

## Chapitre II

## Segmentation d'images médicales

✚ Méthodes qui s'appuient sur les notions de prédicat d'homogénéité et de partition en régions  $\{R_i\}$  de l'image  $I$  vérifient que :

- $\forall i, j (R_i \cap R_j) \neq \emptyset$
- $\forall i, R_i \neq \emptyset$
- $\cup_i R_i = I$

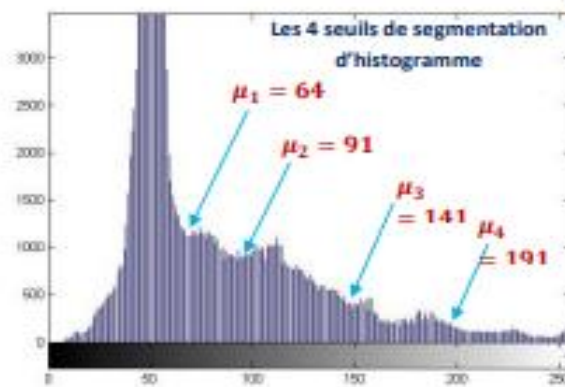


Image couleur

RGB2gray  
→



Image en niveaux de gris



Histogramme

Histogramme de l'image en niveaux de gris

Segmentation multi-seuils




Image segmentée en 5 régions colorées




Image segmentée en 5 régions de gris

## ❖ Quelques critères d'homogénéité d'une région

### → *Contraste sur la région*

$$P(R_k) = \text{vrai} \Leftrightarrow ( \underset{R_k}{\text{Max}} \{ I(x,y) \} - \underset{R_k}{\text{Min}} \{ I(x,y) \} ) < \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil

### → *Ecart-type sur la région*

$$P(R_k) = \text{vrai} \Leftrightarrow \sqrt{\frac{1}{N} \sum_{R_k} ( I(x,y) - m )^2} < \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil
- $N = \text{Card}(R_k)$
- $m = \frac{1}{N} \sum_{R_k} I(x,y)$

### → *Entropie (mesure de la quantité d'information)*

$$P(R_k) = \text{vrai} \Leftrightarrow - \sum_{R_k} ( p(I(x,y)) \log(p(I(x,y))) ) < \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil
- $p(I(x,y))$ , la probabilité d'apparition du niveau de gris  $I(x,y)$

**Figure 1.9** : les critères d'homogénéité d'une région

## 2.4.6 Segmentation par région

Dans cette segmentation, nous développons des régions en incluant de manière récursive les pixels voisins qui sont similaires et connectés au pixel de départ. Nous utilisons des mesures de similarité telles que les différences de niveaux de gris pour les régions avec des niveaux de gris homogènes. Nous utilisons la connectivité pour éviter de connecter différentes parties de l'image.

Il existe deux variantes de segmentation par région :

### Approche descendante

Tout d'abord, nous devons définir le pixel de départ prédéfini. Soit nous pouvons définir tous les pixels comme des pixels de départ ou des pixels choisis au hasard. Agrandissez les régions jusqu'à ce que tous les pixels de l'image appartiennent à la région.

Une approche en profondeur

Sélectionnez la graine uniquement à partir d'objets d'intérêt. Ne cultivez les régions que si le critère de similarité est rempli.

### Mesures de similarité

Les mesures de similarité peuvent être de différents types : Pour l'image en niveaux de gris, la mesure de similarité peut être les différentes textures et autres propriétés spatiales, la différence d'intensité au sein d'une région ou la

- valeur moyenne de la distance n/b de la région.

#### ➤ Techniques de fusion de régions :

- Dans la région technique la fusion, nous essayons de combiner les régions qui contiennent l'objet unique et le séparent de l'arrière – plan. Il existe de nombreuses régions techniques telles que la fusion algorithme du bassin versant, Split et algorithme de fusion, etc .

#### ➤ Avantage :


- Comme il effectue un calcul de seuil simple, il est plus rapide à effectuer.
- La segmentation par région fonctionne mieux lorsque l'objet et l'arrière-plan présentent un contraste élevé.

#### ➤ Limite :

- Il n'a pas produit de nombreux résultats de segmentation précis lorsqu'il n'y a pas de différences significatives entre les valeurs de pixels de l'objet et de l'arrière-plan.

## 2.5 Principe de segmentation

Le principe de segmentation par région est de diviser l'image en plusieurs régions regroupant un groupe de pixels homogènes. Pour créer une région de pixels homogènes, il faut vérifier pour chaque pixel, qu'il est semblable à ses 8 voisins.



**Figure 2.10** :4 voisins diagonaux

Les pixels qui ne sont pas homogènes avec leurs voisins formeront les bords entre la région du pixel et celle du pixel voisin.

Pour une image en noir et blanc, ce procédé peut se traduire par le regroupement des pixels inférieurs à 128 d'un côté et des pixels supérieurs à 128 de l'autre côté.

On peut également imaginer agrandir le nombre de groupes différents (4 régions :  $[0,63],[64,127],[128,191],[192,255]$ ).

Pour une image en couleur, le principe est différent car chaque pixel possède 3 composantes (Rouge, Vert, Bleu). 2 méthodes sont possibles pour opérer la segmentation par régions sur une image en couleur :


### 2.5.1 Balayage

On définit tout d'abord que tous les pixels adjacents possédant les mêmes 3 composantes de couleurs forment une même région. Puis, on effectue un balayage de haut en bas et de droite à gauche de manière à regrouper les régions ayant des caractéristiques similaires, à une erreur près. Cette erreur est généralement représentée par la distance euclidienne entre 2 couleurs.

### 2.5. 2Méthode par indice de similarité

De la même manière que la méthode de balayage, on regroupe d'abord les pixels de même couleurs. Puis, au lieu de balayer l'image, on regroupe les différents pixels ayant des indices de similarité proches.

Après avoir créé différentes régions de pixels similaires, on obtient l'image suivante :



**Figure 1.11** : représentation méthode par indice de similarité

### 2.6 Segmentation par Croissance de Région

#### ❖ Définition grossière

Méthode fondée sur l'agglomération de pixels voisins à une région en maintenant vrai le prédicat d'homogénéité choisi

#### ❖ Principe général

- Approche "ascendante"
- Le processus commence à partir d'un pixel (ou d'un groupe de pixels connexes) d'amorce (germe)
- Considération des pixels voisins et analyse du prédicat d'homogénéité
- Croissance de la région jusqu'au critère d'arrêt (plus aucun pixel ne peut être ajouté sans compromettre l'homogénéité de la région)



**Figure 1.12** : représentation de la croissance de région

### ❖ Avantages et limites

#### ✚ Avantages

- Implémentation de cette méthode relativement simple
- Assez rapide

#### ✚ Limites

- Algorithmes très sensibles au bruit,
- Obtention de frontières non-régulières
- Peu efficace en cas de dégradés d'attributs
- Influence des nombre et ordre de prise en compte des germes, des voisins
- Choix critique des attributs et des valeurs des seuils
- Risque de sur-segmentation ou de sous-segmentation
- Dépend du type d'images à traiter

## 2.7 Segmentation par Partage de Région

### ❖ Définition

L'objectif de cette méthode est de partager l'image à traiter de façon automatique en un ensemble de régions homogènes au regard d'un prédicat d'hétérogénéité  $P'$  choisi.

### ❖ Principe général

- Approche "descendante"
- En général, au départ le prédicat d'homogénéité  $P$  n'est pas respecté sur l'image entière, c'est-à-dire que  $P'$  est vérifié ( $P' = \neg P$ )

- Si P' est vérifié, on divise en régions
- Arrêt du processus lorsqu'aucune région n'est hétérogène




Figure 1.13 : représentation d Segmentation par Partage de Région

### ❖ Quelques critères d'hétérogénéité d'une région

#### → Contraste sur la région

$$P'(R_k) = \text{vrai} \Leftrightarrow (\text{Max}_{R_k} \{ I(x,y) \} - \text{Min}_{R_k} \{ I(x,y) \} ) > \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil

#### → Ecart-type sur la région

$$P'(R_k) = \text{vrai} \Leftrightarrow \sqrt{\frac{1}{N} \sum_{R_k} (I(x,y) - m)^2} > \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil
- $N = \text{Card}(R_k)$
- $m = \frac{1}{N} \sum_{R_k} I(x,y)$

#### → Entropie (mesure de la quantité d'information)

$$P'(R_k) = \text{vrai} \Leftrightarrow -\sum_{R_k} (p(I(x,y)) \log(p(I(x,y)))) > \sigma$$

avec :

- $I$ , une image,
- $R_k$ , une région quelconque de  $I$ ,
- $\sigma$ , un seuil
- $p(I(x,y))$ , la probabilité d'apparition du niveau de gris  $I(x,y)$

Figure 1.14: les critères d'hétérogénéité d'une région

### 2.8 Conclusion

Dans ce chapitre nous avons abordé les différents types de segmentation d'image leur avantage et limite, principe. Nous avons aussi discuté sur la Segmentation par région

Dans le chapitre qui suivra, nous aborderons Réseaux de neurones et apprentissage profond qui sera utilisé dans le traitement d'image dans les capteurs(CNN).

## 3.1 Introduction

Les réseaux des neurones formels sont des structures la plupart du temps simulés par des algorithmes exécutés sur les ordinateurs d'usage général, parfois sur des machines ou même des circuits spécialisés, qui prennent leurs inspirations à partir du fonctionnement élémentaire des systèmes nerveux. Ils sont utilisés essentiellement pour résoudre des problèmes de classification, de reconnaissance de formes, d'association, d'extraction de caractéristique, et d'identification,... etc.

Un des types de réseaux de neurones profonds le plus populaire est le réseau de neurones à convolution (Convolutional Neural Network ou CNN). [8]

Un CNN utilise des couches à convolution afin d'extraire des caractéristiques directement à partir des données. Son architecture est parfaitement adaptée au traitement des données matricielles telles que les images. [8]

Les réseaux de neurones à convolution éliminent la nécessité d'effectuer une extraction de caractéristiques manuelle, qui est généralement une tâche fastidieuse. Les caractéristiques utilisées ne sont pas pré entraînés, c'est à dire que le réseau les apprend lui-même en s'entraînant sur des images. [8] Cette extraction automatisée des caractéristiques permet aux CNN d'atteindre des performances élevées en classification d'objets.

La complexité des caractéristiques apprises augmente avec le nombre de couches cachées du réseau. La première couche cachée peut par exemple apprendre à détecter les contours de l'image, tandis que la dernière apprend à détecter des formes plus complexes spécialement adaptées à la forme de l'objet que l'on vise à reconnaître. [8] Nous allons décrire dans ce chapitre les réseaux de neurones à convolution et leurs applications à la classification des textures.

## 3.2 Historique

Le premier réseau de neurones convolutif a été en réalité développé en 1998 par le chercheur français Yann LeCun. [8]

Ce réseau appelé LeNet a permis d'atteindre de très bonne performance en reconnaissance des caractères, Bien que cette approche donne des résultats, ses progrès et son évolution ont été limités par les progrès technologiques en matière de micro-processeurs, de puissance de calculs, et du manque d'accessibilités à des données afin de pouvoir entraîner les neurones. [8]

Cependant certains chercheurs ont continué à travailler sur ce modèle pendant environ deux décennies. [8] Et, avec l'aide des évolutions en matière de technologies mais surtout avec la disponibilité toujours plus grande de données, ont pu améliorer cette technique. [8]

Ce n'est qu'en 2012 que le Deep Learning est remis au goût du jour en remportant avec succès le concours de reconnaissance d'image fondé par l'université de Stamford (Large Scale Visual Recognition Challenge: ILSVRC) grâce à l'évolution en matière de technologies et à la disponibilité toujours plus grande de données. [8]

Un nouvel algorithme de Deep Learning explose les records Il s'agit d'un réseau de neurones convolutif appelé AlexNet, largement inspiré du réseau LeNet.

ImageNet regroupant 15 000 000 d'images naturelles comportant différents objets et diverses scènes (véhicules, animaux,). [8] Aujourd'hui, les réseaux de neurones convolutifs, sont toujours les modèles les plus performants pour la classification d'images. [8] Google, Microsoft, Facebook, Baidu (le moteur de recherche chinois), Alibaba (site marchand chinois), Nvidia (géant du processeur graphique) utilisent les CNN dans leurs applications. [8]

### 3.3 Les Réseaux de neurones

Tout d'abord, le réseau de neurones est un concept. Ce n'est pas physique. Le concept de réseaux de neurones artificiels (Artificial Neural Networks ANN) (figure III.2) a été inspiré par les neurones biologiques (figure III.1). Dans un réseau de neurones biologiques, plusieurs neurones travaillent ensemble, reçoivent des signaux d'entrée, traitent des informations et déclenchent un signal de sortie. Il s'agit là d'une variété de technologie Deep Learning (apprentissage profond), qui fait elle-même partie de la sous-catégorie d'intelligence artificielle du Machine Learning (apprentissage automatique). [9]



**Figure3.1** : Représentation du réseau de neurones humain




Figure 3.2 : Représentation du réseau de neurones artificiel

### 3.4 Principe de Fonctionnement des réseaux de neurones

En règle générale, un réseau de neurones repose sur un grand nombre de processeurs opérant en parallèle et organisés en tiers. Le premier tiers reçoit les entrées d'informations brutes, un peu comme les nerfs optiques de l'être humain lorsqu'il traite des signaux visuels. Par la suite, chaque tiers reçoit les sorties d'informations du tiers précédent.

On retrouve le même processus chez l'Homme, lorsque les neurones reçoivent des signaux en provenance des neurones proches du nerf optique. Le dernier tiers, quant à lui, produit les résultats du système. Les réseaux de neurones apprennent par le biais d'un algorithme, le réseau de neurones artificiels permet à l'ordinateur d'apprendre à partir de nouvelles données. L'ordinateur doté du réseau de neurones apprend à effectuer une tâche en analysant des exemples pour s'entraîner.

Ces exemples ont préalablement été étiquetés afin que le réseau puisse savoir ce dont s'agit. Par exemple, un réseau de neurones peut être utilisé pour apprendre à l'ordinateur à reconnaître des objets. Un grand nombre d'objets d'une même catégorie est présenté au réseau de neurones, et l'ordinateur apprend à reconnaître cet objet sur de nouvelles images en analysant les patterns récurrents au sein des images d'exemple. Ainsi, en analysant des milliers de photos de chats, le Neural Network apprendra à reconnaître un chat sur n'importe quelle photo.

Contrairement à d'autres types d'algorithmes, les réseaux de neurones ne peuvent pas être programmés directement pour effectuer une tâche. A la manière du cerveau en développement d'un enfant, la seule instruction qu'ils ont est d'apprendre. On distingue toutefois trois méthodes d'apprentissage distinctes. Dans le cas de l'apprentissage supervisé, l'algorithme

s'entraîne sur un ensemble de données étiquetées et se modifie jusqu'à être capable de traiter le dataset pour obtenir le résultat souhaité.

Dans le cas de l'apprentissage non-supervisé, les données ne sont pas étiquetées. Le réseau de neurones analyse l'ensemble de données, et une fonction-coût lui indique dans quelle mesure il est éloigné du résultat souhaité. Le réseau s'adapte alors pour augmenter la précision de l'algorithme. Enfin, avec la méthode de l'apprentissage renforcé, le réseau de neurones est renforcé pour les résultats positifs et sanctionné pour les résultats négatifs. C'est ce qui lui permet d'apprendre au fil du temps, de la même manière qu'un humain apprend progressivement de ses erreurs. [10]

### 3.5 Les différents types de réseaux de neurones

Il existe différents types de réseaux de neurones. Les deux réseaux de neurones les plus populaires sont :

#### 3.5.1 Réseau de neurones récurrent – Recurrent Neural Network (RNN)

Ce sont des réseaux de neurones spécialisés qui utilisent le contexte des entrées lors du calcul de la sortie. La sortie dépend des entrées et des sorties calculées précédemment. Ainsi, les RNN conviennent aux applications où les informations historiques sont importantes. Ces réseaux nous aident à prévoir les séries chronologiques dans les applications commerciales et à prévoir les mots dans les applications de type chatbot. Ils peuvent fonctionner avec différentes longueurs d'entrée et de sortie et nécessitent une grande quantité de données. [11]

#### 3.5.2 Réseau de neurones convolutif – Convolution Neural Network (CNN)

Ces réseaux reposent sur des filtres de convolution (matrices numériques). Les filtres sont appliqués aux entrées avant que celles-ci ne soient transmises aux neurones. Ces réseaux de neurones sont utiles pour le traitement et la prévision des signaux et d'images. Comparés à d'autres algorithmes de classification, les réseaux de neurones convolutifs utilisent relativement peu de pré-traitement. Cela signifie que le réseau est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision), ce qui n'est pas le cas d'autres algorithmes plus traditionnels. L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN. [11] Dans l'optique de trouver une architecture de réseau robuste et indépendante des techniques d'extraction de caractéristiques tout en donnant des performances satisfaisantes pour les signaux bruyants dans la classification, Nauman Munir« ingénieur en

Département de Mécanique à l'université Sungkyunkwan et chercheur à l'Institut nucléaire à la Corée a fait une comparaison dans son article [12] entre la convolution des réseaux de neurones CNN et d'autres architectures dans la classification des défauts de soudures. L'ingénieur a conclu que le CNN a donné de meilleurs résultats dans des conditions bruyantes. Ce qui nous a conduit à choisir ce type de réseaux de neurones CNN dans notre application

### 3.6 Convolution Neural Network (CNN)

Les réseaux de neurones convolutifs (CNN ou ConvNet - Convolutional Neural Network) sont un type particulier de réseaux de neurones multi-couches feed forwards souvent utilisés en traitement d'images, introduits initialement par Fukushima en 1980 pour une tâche de reconnaissance de forme dont l'architecture du réseau est inspirée du cortex visuel des animaux et popularisés pour la tâche de la reconnaissance de caractères. Aujourd'hui, les CNNs sont devenus populaires dans plusieurs applications d'intelligence Artificielle en traitement automatique des langues : classification de texte, classification de musique et d'environnements sonores et traitement de signal. [13]

#### 3.6.1 Le principe de la CNN

Le réseau neuronal convolutionnel est un type de réseau neuronal profond qui possède des couches convolutionnelles ainsi que des couches entièrement connectées. La convolution est une fonction mathématique largement appliquée dans le domaine du traitement du signal. Dans le réseau neuronal convolutif, les couches convolutives utilisent en fait la technique de corrélation croisée qui est techniquement très similaire à la convolution. Il existe deux couches importantes dans les réseaux neuronaux convolutifs, à savoir les couches d'extraction de caractéristiques et les couches de classification.

La couche convolutionnelle et les couches de mise en commun sont des couches d'extraction de caractéristiques, tandis que les couches de classification sont entièrement connectées. Les couches convolutionnelles, contrairement aux couches pleinement connectées, ne sont pas connectées à tous les nœuds de la couche d'entrée, mais à des régions locales spécifiques basées sur les filtres/ noyaux convolutifs définis. Cette architecture permet au réseau de se concentrer sur les caractéristiques de bas niveau, qui sont ensuite assemblées en caractéristiques de haut niveau. Le CNN est également capable d'apprendre des motifs [13] Nous allons utiliser le CNN pour la classification des défauts détectés par le contrôle non destructif par ultrason.

### 3.6.2 Les dimensions de la CNN

Il existe 3 types d'opérations de convolution avec différentes dimensions 1D, 2D et 3D. La différence entre ces types de convolution s'exprime essentiellement au niveau des tailles des filtres, du nombre de direction de mouvement des filtres sur l'entrée A ainsi que de la dimension de la carte de caractéristiques produite en sortie. [13]

- **CNN 1 dimensionnel | Conv1D :**

Elle est utilisée sur les séries temporelles, les données audio et textuelles car nous pouvons également représenter le son et les textes comme des données de séries temporelles.

- **CNN à 2 dimensions | Conv2D :**

Il s'agit du réseau neuronal à convolution standard qui a été introduit pour la première fois dans l'architecture Lenet-5. Conv2D est généralement utilisé sur des données d'image. Il est appelé CNN bidimensionnel parce que le noyau glisse le long de deux dimensions sur les données.

- **CNN tridimensionnel | Conv3D :**


Elle est utilisée avec des données d'images 3D. Comme les données d'imagerie par résonance magnétique (IRM). Les données IRM sont largement utilisées pour examiner le cerveau, la moelle épinière, les organes internes, etc.

### 3.7 Les principaux composants du CNN

Trois types de couches (en anglais Layers) composent le CNN : convolutional layers, pooling layers and 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 function et loss function qui sont définis ci-dessous. [20]

#### 3.7.1 1D Convolutional layers

Cette couche est la première couche qui est utilisée pour extraire les différentes caractéristiques du Data d'entrée. Dans cette couche, l'opération mathématique de convolution est effectuée entre le Data d'entrée et un filtre d'une taille particulière  $M \times M$ . En faisant glisser le filtre sur le Data, le produit scalaire est pris entre le filtre et les parties du Data d'entrée par rapport à la taille du filtre ( $M \times M$ ). (Voir figure III.3) [14]




**Figure 3.3 :** exemple d'un filtre de convolution 1D

Pour chaque couche de convolution il existe une fonction d'activation L'un des paramètres les plus importants du modèle CNN. Elles sont utilisées pour apprendre et approximer tout type de relation continue et complexe entre les variables du réseau. En d'autres termes, elle décide quelles informations du modèle doivent être tirées dans la direction avant et lesquelles ne doivent pas l'être à la fin du réseau. Elle ajoute une non-linéarité au réseau.

Il existe plusieurs fonctions d'activation couramment utilisées, telles que les fonctions ReLU, Softmax, Linear, TanH et Sigmoid (figure III.4). [14]

Chacune de ces fonctions à un usage spécifique. Pour un modèle CNN de classification binaire, les fonctions sigmoïdes et softmax sont préférées et pour une classification multiclassées, on utilise généralement softmax. A la fin La sortie est appelée carte de caractéristiques qui nous donne des informations sur le Data. Plus tard, cette est introduite dans d'autres couches pour apprendre plusieurs autres caractéristiques du Data d'entrée.




**Figure 3.4 :** Les fonctions D'activation

### 3.7.2 Pooling layers

Dans la plupart des cas, une couche convolutive est suivie d'une couche de mise en commun. L'objectif principal de cette couche est de diminuer la taille de la carte de caractéristiques

convolutionnelle afin de réduire les coûts de calcul. Ceci est réalisé en diminuant les connexions entre les couches et en opérant indépendamment sur chaque carte de caractéristiques. Selon la méthode utilisée, il existe plusieurs types d'opérations de pooling. [14]

Dans le cas du Maxpooling (figure III.5), l'élément le plus grand est extrait de la carte de caractéristiques. Le pooling moyen calcule la moyenne des éléments dans une section d'image de taille prédéfinie. La somme totale des éléments dans la section prédéfinie est calculée dans Sum Pooling. La couche pooling sert généralement de pont entre la couche de convolution et la couche FC. [14]



**Figure 3.5** : Exemple sur le Maxpooling

### 3.7.3 Fully connected layers (FC)

La couche entièrement connectée (FC) se compose des poids et des biais avec les neurones et est utilisée pour connecter les neurones entre deux couches différentes. Ces couches sont généralement placées avant la couche de sortie et forment les dernières couches d'une architecture CNN. (Voir figure III.6). Dans cette couche, le Data des couches précédentes est aplati et transmise à la couche FC. Le vecteur aplati passe ensuite par quelques couches FC supplémentaires où les opérations de fonctions mathématiques ont généralement lieu. A ce stade, le processus de classification commence à avoir lieu. [14]




Figure 3.6 : Représentation des fully-connected Layers

### 3.7.4 Dropout layers

Habituellement, lorsque toutes les caractéristiques sont connectées à la couche FC, cela peut entraîner un surajustement dans l'ensemble de données d'apprentissage. Le surajustement se produit lorsqu'un modèle particulier fonctionne si bien sur les données d'apprentissage qu'il a un impact négatif sur les performances du modèle lorsqu'il est utilisé sur de nouvelles données. [14] Pour surmonter ce problème, on utilise une couche d'exclusion dans laquelle quelques neurones sont éliminés du réseau neuronal pendant le processus de formation, ce qui réduit la taille du modèle. Lorsque la couche d'exclusion est égale à 0,3, 30 % des nœuds sont éliminés de manière aléatoire du réseau neuronal. (Voir figure III.7)




Figure 3.7 : Exemple sur le fonctionnement des Dropout Layers

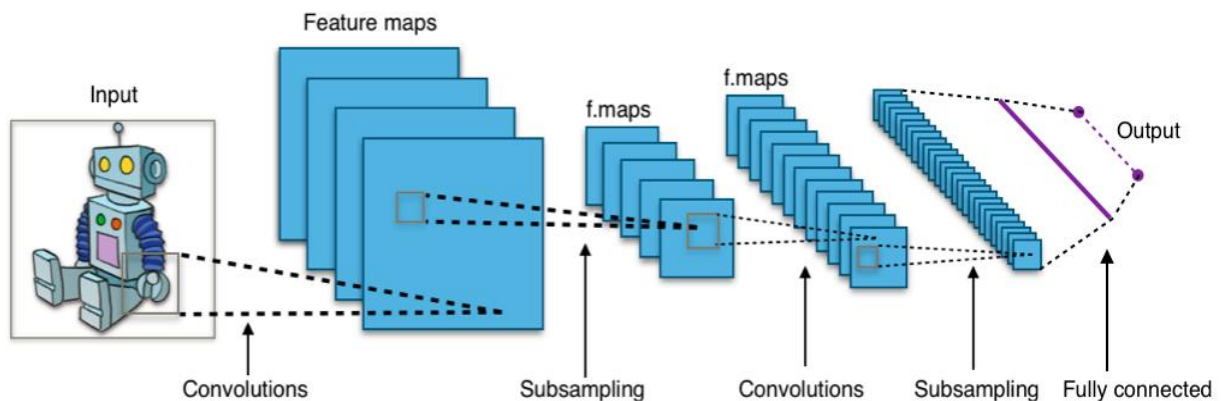
### 3.7.5 Loss function

La couche de perte est la dernière couche du réseau. Elle calcule l'erreur entre la prévision du réseau et la valeur réelle. Lors d'une tâche de classification, la variable aléatoire est discrète,

car elle peut prendre uniquement la valeur 0 ou 1, représentant l'appartenance (1) ou non (0) à une classe. C'est pourquoi la fonction de perte la plus courante et la plus adaptée est la fonction d'entropie croisée (en anglais cross-entropy). [14]

## 3.8 Architecture

Les réseaux de neurones à convolution sont basés sur le perceptron multicouche (MLP), et inspirés du comportement du cortex visuel des vertébrés. Bien qu'efficaces pour le traitement d'images, les MLP ont beaucoup de mal à gérer des images de grande taille, ce qui est dû à la croissance exponentielle du nombre de connexions avec la taille de l'image. Un réseau de neurone convolutif se compose de plusieurs couches comme le montre la figure



**Figure3.8** : réseaux de neurone convolutif [11]

## 3.9 Couche CNN

Une architecture CNN est formée par un empilement de couches de traitement indépendantes [17]:

- La couche de convolution (CONV) qui traite les données d'un champ récepteur.
- La couche de pooling (POOL), qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous-échantillonnage).
- La couche de correction (ReLU), souvent appelée par abus 'ReLU' en référence à la fonction d'activation (Unité de rectification linéaire).
- La couche "entièrement connectée" (FC), qui est une couche de type perceptron.
- La couche de perte (LOSS).


## 3.9.1 Couche de convolution(CONV)

Le terme ‘convolution’ vient du fait que les réseaux CNN utilisent des opérations de convolution comme dans le traitement du signal ou d’images. [14] Dans la couche de convolution, on applique un produit de convolution entre l’image originale ou celle obtenue dans la couche précédente avec un filtre dont des coefficients sont assimilés à des poids synaptiques. [14] Le produit de convolution d’une matrice (image ou vecteur de mot dans ce cas) I avec un filtre K de taille (s\*s) est :

$$O(x, y) = \sum_{i=0}^2 \sum_{j=0}^2 K(i, j) \times I(x - 1 + j, y - 1 + i)$$

Il y a trois paramètres permettant de dimensionner le volume de la couche de convolution la profondeur, le pas et la marge :

- Profondeur de la couche : Nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).
- Le pas: Contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
- La marge (à 0) ou zero padding: Parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zero-padding' est le troisième hyper paramètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée. Cette marge permet de contrôler la dimension spatiale volume de sortie. En particulier.



**Figure 3.9** :Exemple de filtre de taille (3\*3)

## 3.9.2 Couche de pooling (POOL)

La couche de pooling (en anglais pooling layer) (POOL) est une opération de sous échantillonnage typiquement appliquée après une couche convolutionnelle. [14] En particulier, les types de pooling les plus populaires sont le max et l'average pooling, où les valeurs maximales et moyennes sont prises, respectivement. [14]

La couche de pooling permet de réduire le nombre de paramètres par conséquent d'accélérer les calculs dans le réseau. Elle permet aussi d'améliorer l'efficacité du réseau et éviter le problème sur-apprentissage. [14]

- **Max pooling**

Chaque opération de pooling sélectionne la valeur maximale de la surface




Figure 3.10 : Max pooling

- **Commentaires :**

- Garde les caractéristiques détectées
- Plus communément utilisé Average pooling Chaque opération de pooling sélectionne la valeur moyenne de la surface




Figure 3.11 : Average pooling

- **Commentaires :**

- Sous-échantillonne la feature map
- Utilisé dans LeNet

## 3.9.3 La couche de correction ReLU

ReLU (Rectified Linear Units) désigne la fonction réelle non-linéaire définie par  $\text{ReLU}(x) = \max(0, x)$ . [19] La couche de correction ReLU remplace donc toutes les valeurs négatives reçues en entrées par des zéros. Elle joue le rôle de fonction d'activation. [19]




Figure 3.12 : Allure de la fonction ReLU

## 3.9.4 Le flattening (ou mise à plat)

Dernière étape de la partie “extraction des informations”, le flattening consiste simplement à mettre bout à bout toutes les matrices que nous avons pour en faire un (long) vecteur. Les pixels (en réalité ce ne sont plus des images ou des pixels (vecteur de mot dans notre cas), mais des matrices de nombres, donc les pixels sont ces nombres) sont récupérés ligne par ligne et ajoutés au vecteur final.

### 3.9.4.1 Quel est l'intérêt de cette étape ?

En fait, le réseau de neurones prend simplement en entrée un vecteur (à chaque neurone d'entrée on envoie une seule valeur). Par conséquent, dans l'absolu, rien n'empêche d'utiliser un flattening qui lit les matrices par colonne, ou même qui mélange tous les “pixels (mot ou phrase)” (sans en changer les valeurs), tant que le procédé de flattening reste toujours le même.

## 3.9.5 La partie “fully connected” ou “dense” alias le réseau de neurones artificiels (perceptron multi-couches)


Nous l'avons déjà expliqué le sujet dans le premier chapitre, De manière synthétique, un réseau de neurones artificiels est un réseau qui contient des neurones, dans le cas du CNN, ce

sera la valeur d'un pixel (mot ou phrase) précis pour chaque neurone (tout simplement, en suivant l'ordre du vecteur). [14]

### 3.9.6 Bonus : le padding

Parfois, il peut être intéressant de conserver une certaine dimension dans les tailles des images en sortie des convolutions. Le padding consiste simplement à ajouter des 0 tous autour d'une matrice pour en augmenter la taille. [14]

Par exemple, un padding de 2 sur une matrice de taille 32×32 ajoutera des 0 à gauche sur 2 colonnes, à droite sur 2 colonnes, en haut sur 2 lignes et en bas sur 2 lignes !



**Figure 3.13 :** Padding de 2 autour d'une image de taille 32×32.

Nous avons à présent tous les outils pour comprendre l'architecture d'un réseau de neurones convolutif. Il en existe plusieurs dans la littérature dont l'efficacité varie en fonction de la tâche, car ils n'ont pas tous le même nombre de convolutions (ni la même structure).

### 3.10 Paramètres des CNN

Nous devons choisir dans les CNNs le nombre de couches de convolution, de correction ReLu, de pooling, et de couches entièrement connectées. Il faut également définir les paramètres pour chaque couche de convolution et de pooling. [14]

Trois paramètres permettent de dimensionner une couche de convolution : le nombre de noyaux de convolution, le pas de chevauchement et la marge à zéro (zéro padding) qui définit le nombre de zéros sur les frontières des cartes, même s'il est parfois souhaitable de conserver la même surface que celle des cartes d'entrée. Concernent la couche de pooling, celle-ci est

définie par la taille de la fenêtre de traitement et par le pas de chevauchement. En pratique, une fenêtre de  $(2*2)$  avec un pas de 1 sont souvent choisis. [14]

### 3.11 Avantages de CNN

Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution. Cette méthode réduit l'empreinte mémoire, améliore les performances et permet une invariance du traitement par translation. C'est le principal avantage du réseau de neurones convolutifs par rapport au perceptron multicouches, qui, lui, considère chaque neurone indépendant et affecte donc un poids différent à chaque signal entrant. [14]

### 3.12 Conclusion

Dans ce chapitre, les réseaux de neurones convolutionnels ont été définis et leur rôle a été mis en relief. Ces réseaux sont capables d'extraire des caractéristiques d'images ou des données en général, présentées en entrée et de classifier ces données en se basant sur les caractéristiques (de ces données) extraites automatiquement. Nous avons présenté ensuite les réseaux de neurones et ses différents types ainsi que les choix de l'architecture et le fonctionnement de base d'un réseau de neurones convolutif simple en détaillant les différents blocs de construction : l'entrée du réseau, l'opération de convolution, l'opération de pooling ainsi que la fonction d'activation et la fonction Loss permettant d'adapter la sortie du réseau en fonction de la tâche visée

## 4.1 Introduction

Dans ce chapitre, nous discutons des aspects de conception de notre système, avec différentes présentations de schémas de conception, qui décrivent la structure et le fonctionnement de notre système de classification des tumeurs.

Ensuite, nous commençons à afficher l'environnement de travail, dans les différents détaillants qui ont utilisé les outils. Nous offrirons également différentes interfaces système principal. Nous avons intéressé sur le dénombrement des cancers est un énorme problème de santé publique dans le monde. Selon des données provenant d'une partie de l'Organisation mondiale de la Santé (OMS), le centre international de recherche sur le cancer (CIRC), 8,2 millions de personnes sont mortes du cancer en 2012, et 27 millions de nouveaux cas de cancer sont attendus d'ici 2030. Parmi les cancers, le cancer du sein (C.-B.) est le deuxième cancer le plus fréquent chez les femmes (à l'exclusion du cancer de la peau).

De plus, comparativement à d'autres types de cancer, le taux de mortalité en Colombie-Britannique est très élevé. Malgré les derniers développements dans la compréhension de la biologie moléculaire des progrès du CN et la découverte de nouveaux marqueurs moléculaires pertinents, l'analyse des tissus demeure la méthode la plus couramment utilisée pour le diagnostic du CN. Malgré des progrès importants dans la technologie d'imagerie diagnostique, les pathologistes effectuent un diagnostic final BC (y compris les grades et les grades) en examinant visuellement des échantillons de tissus sous un microscope.

## 4.2 Présentation de l'application développée

### 4.2.1 Environnement de travail

L'environnement de travail est constitué par deux parties : environnement matériel et environnement logiciel.

- **Environnement matériel**

L'application a été développée sur un Pc ayant les caractéristiques suivantes :

- **Ordinateur** : DELL.
- **Processeur** : Intel(R) Core(TM) i5-4210U CPU @ 1.8 GHz 1.8GHz.
- **Type de système** : Windows10.
- **RAM** : 8.00 Go.

▪ **Carte graphique** : NVIDIA GeForce840M

- **Environnement logiciel**

L'environnement logiciel consiste en les composants suivants :

MATLAB est un langage de programmation simple signifie : « **Matrix laboratory** », développée par la société «The Math Works ». Il a été initialement conçu par « CleveMoler » à la fin des années 1970. MATLAB est un langage de développement informatique particulièrement dédié aux applications scientifiques. Il est utilisé pour développer des applications nécessitant une très grande puissance de calcul. Il permet également de manipuler des matrices, d'afficher des courbes et des données, de mettre en œuvre des algorithmes, de créer des interfaces utilisateurs, et peut s'interfacer avec d'autres langages comme le C, C++, Java, et Fortran.

MATLAB est un environnement puissant, complet en plus de sa disponibilité est assurée sur plusieurs plate formes : Sun, Bull, HP, IBM, compatible PC (DOS, Unix ou Windows), Machintosh, iMac et plusieurs machines parallèles. Il est aussi un environnement de visualisation de données qui existe depuis plus de 10 ans. Son objectif, par rapport aux autres langages, est de simplifier au maximum la transcription en langage informatique d'un problème mathématique, en utilisant une écriture la plus proche possible du langage naturel scientifique [15]

Dans notre projet nous avons utilisées la version MATLAB R2020a. Permet les raisons qui nous ont poussées à utiliser, on trouve :

- Ses très nombreuses fonctions prédéfinies et prête à l'emploi
- Sa simplicité a l'implémentation et de calculs.
- Sa fiabilité et sa robustesse.
- La syntaxe de Matlab est facile à assimiler.
- La figure (IV.1) illustre l'interface d'accueil de MATLAB R2020a




Figure 4.1 : La page d'accueil de MATLAB R2020a

### 4.3 Introduction à U-Net

L'architecture U-Net, publiée pour la première fois en 2015, a été une révolution dans le domaine de l'apprentissage en profondeur. L'architecture a remporté le défi de suivi des cellules du Symposium international sur l'imagerie biomédicale (ISBI) de 2015 dans de nombreuses catégories par une large marge. Certains de leurs travaux incluent la segmentation des structures neuronales dans des empilements de microscopie électronique et des images de microscopie à lumière transmise.

Avec cette architecture U-Net, la segmentation des images de tailles 512X512 peut être calculée avec un GPU moderne en peu de temps. Il y a eu de nombreuses variantes et modifications de cette architecture en raison de son succès phénoménal. Certains d'entre eux incluent LadderNet, U-Net avec attention, le U-Net convolutionnels récurrent et résiduel (R2-UNet) et U-Net avec des blocs résiduels ou des blocs avec des connexions denses [16].

4.4 L'architecture U-Net

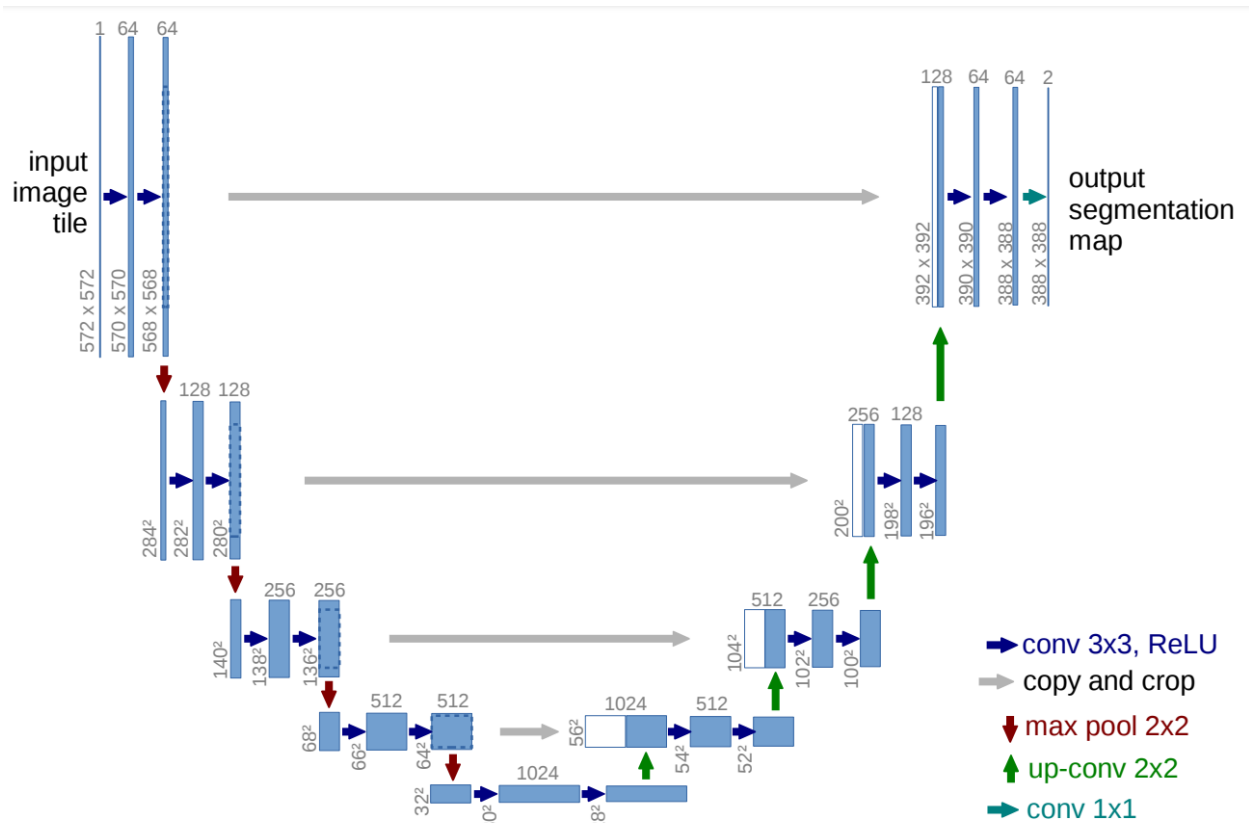


Figure 4.2 : l'architecture U-Net

4.4.1 La base de données image

Concernant la base de données, nous avons quatre fichiers contenant plusieurs images IRM.

- ✓ Le premier fichier <GT><GTtest> contient 33 images IRM originales dans plusieurs positions.
- ✓ Le deuxième fichier <ref><refest> se compose de 33 images segmentées montrant des zones de la tumeur sous différents angles.

4.4.2 Les résultats obtenus

Dans l'atmosphère initiale, nous obtenons l'image segmentée par un réseau de neurones convolutifs, où lorsque  $k = 1, 10, 20, 33$ , nous obtenons les résultats suivants :

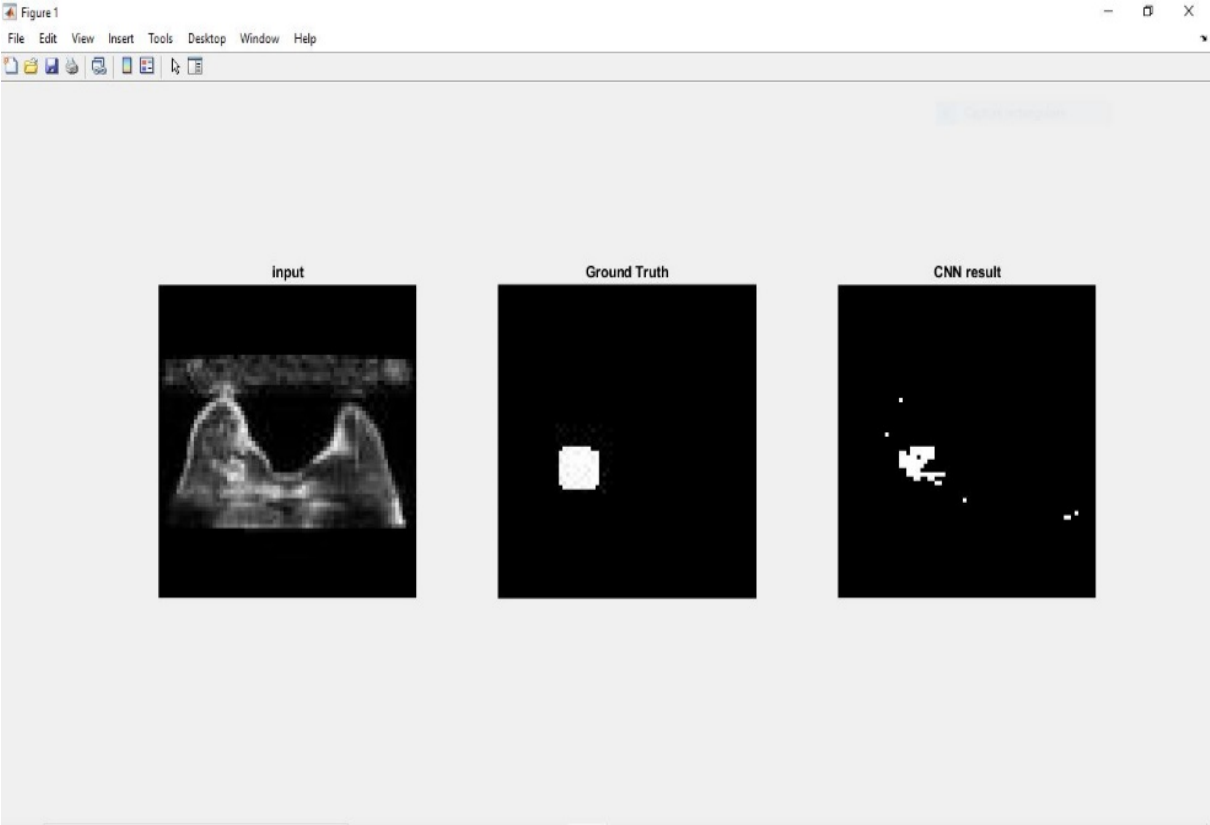


Figure 4.3: l'imagerésultats Vérité terrain, original image,CNN résultat ,K=1

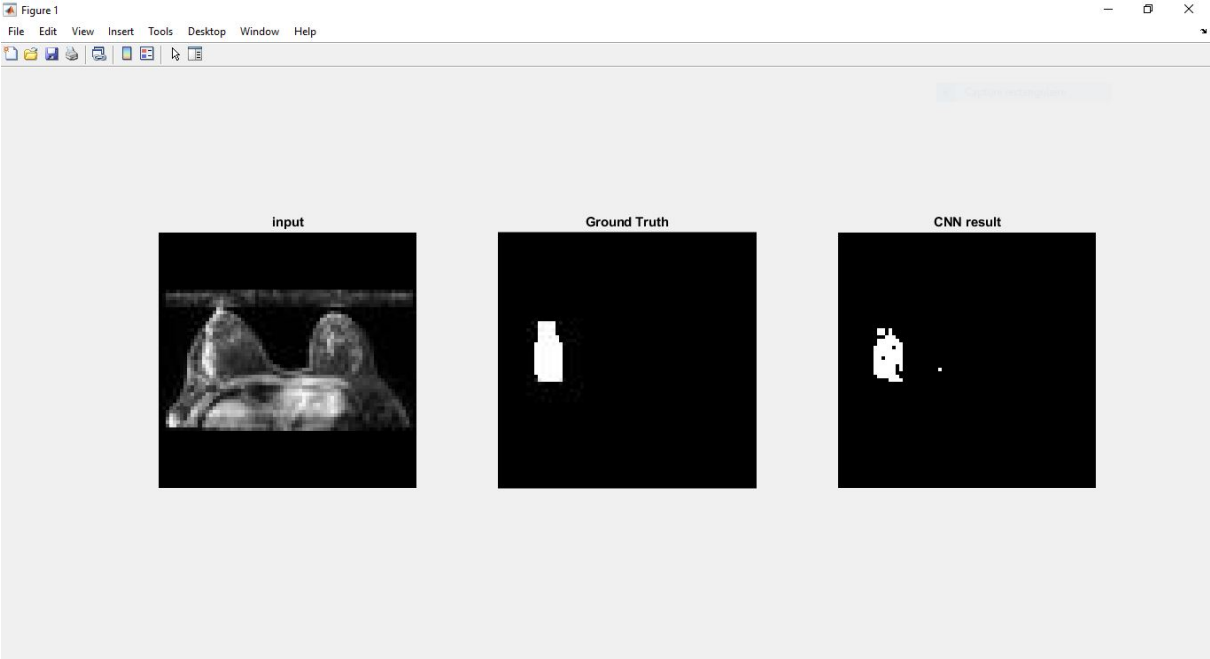
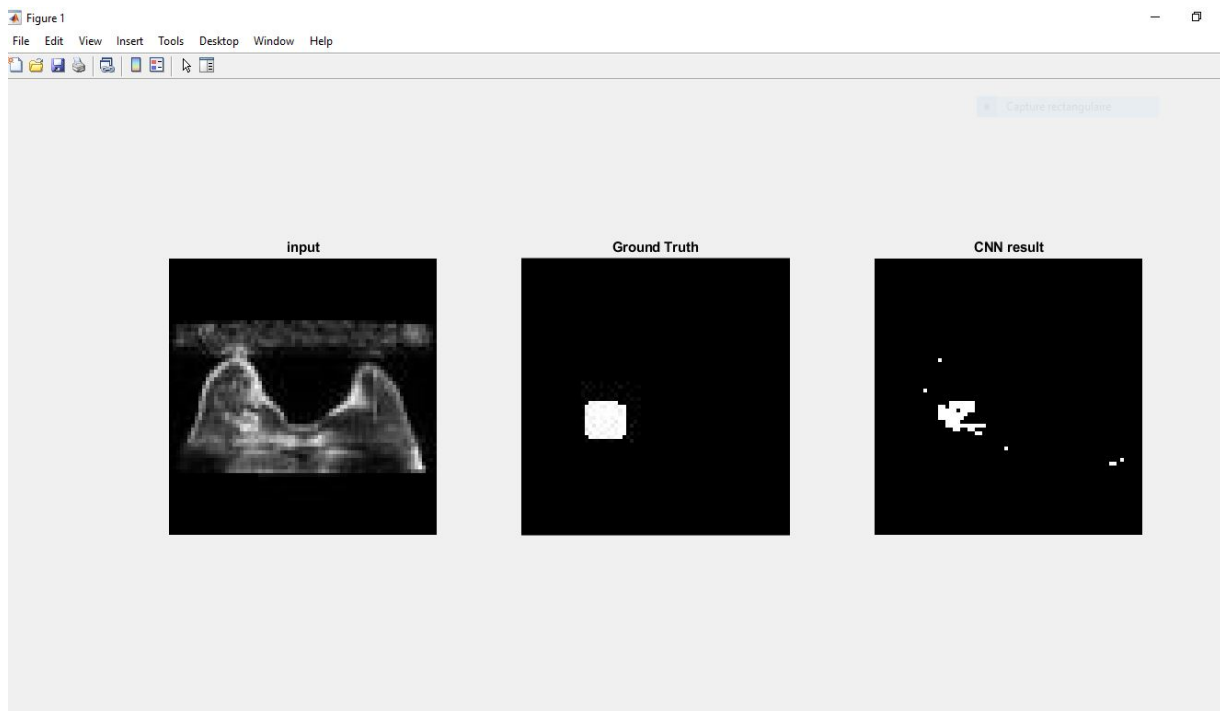


Figure 4.4 : Les images de gauche à droite image originale, Vérité terrain, CNN résulte, K=10



**Figure 4.5** Les images de gauche à droite image originale, Vérité terrain, CNN résultat,  $K=20$



**Figure 4.6:** Les images de gauche à droite image originale, Vérité terrain, CNN résultat,  $K=33$ .

## 4.5 Les critères d'évaluation

### 4.5.1 La précision (Accuracy )

La précision indique le pourcentage de pixels correctement identifiés pour chaque classe. Elle s'agit d'une mesure qui vise davantage à détecter les faux positifs et négatifs dans les résultats du modèle. Pour chaque classe, la précision est le rapport entre les pixels correctement classés et le nombre total de pixels de cette classe, selon la vérité terrain. En d'autres termes :

$$\text{Score de précision} = \frac{TP}{(TP+FN)}$$

(1)

- **TP** : C'est le nombre de vrais pixels positifs et FN est le nombre de faux pixels négatifs.

Pour l'ensemble de données agrégées, Mean Accuracy est une précision moyenne toutes les catégories dans toutes les photos. Pour chaque image, Mean Accuracy est l'exactitude moyenne de toutes les catégories de cette image particulière.

La précision totale est le rapport pixels correctement classés, quel que soit leur rang, au nombre total de pixels. Utiliser une échelle de résolution générale et peu coûteuse pour le ratio de pixels Correctement classifié.

- **QC :**

<b>K</b>	1	10	20	33
<b>QC</b>	0.1347	0.3709	0.4699	0.2853
<b>ACC</b>	0.9770	0.9709	0.9765	0.9755

**Tableau1** : Tableau de résultats des calculs Acc, Qc

Les valeurs moyennes de la précision et la quantification et leurs erreurs quadratiques moyennes

<b>Total_accuracy</b>	<b>Total_Q</b>	<b>std_accuracy</b>	<b>Std_Q</b>
0.9721	0.3243	0.0048	0.0747

**Tableau2** : Résultats total des calculs ACC, QC

## 4.6 Training on single CPU000

Le tableau nous montre :

- Le rapport complet sur l'entraînement des réseaux de neurones et
- Donnez-nous des informations sur son fonctionnement en fonction du temps dans
- Déterminer le taux de perte, la précision et le nombre de répétitions effectuées

```
Command Window
Training on single CPU.
Initializing input data normalization.
```

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	00:00:00	39.36%	0.9786	0.0100
2	50	00:00:10	66.69%	0.9090	0.0100
4	100	00:00:19	80.84%	0.9081	0.0100
6	150	00:00:29	94.86%	0.7898	0.0100
8	200	00:00:38	95.39%	0.7309	0.0100
10	250	00:00:48	95.56%	0.6586	0.0100
12	300	00:00:57	95.96%	0.6235	0.0100
14	350	00:01:07	95.95%	0.5824	0.0100
16	400	00:01:16	95.70%	0.7168	0.0100
18	450	00:01:25	96.22%	0.6905	0.0100
20	500	00:01:36	96.41%	0.5384	0.0100
22	550	00:01:45	96.07%	0.6263	0.0100
24	600	00:01:54	96.63%	0.5688	0.0100
25	650	00:02:03	96.11%	0.6176	0.0100
27	700	00:02:12	96.40%	0.6467	0.0100
29	750	00:02:20	96.64%	0.5941	0.0100
31	800	00:02:29	96.56%	0.5086	0.0100
33	850	00:02:38	96.64%	0.5479	0.0100
35	900	00:02:47	96.56%	0.4873	0.0100
37	950	00:02:56	96.44%	0.5253	0.0100
39	1000	00:03:06	96.42%	0.4846	0.0100

Command Window						
110	2850	00:08:30	96.50%	0.4722	1.0000e-04	
112	2900	00:08:39	96.65%	0.4824	1.0000e-04	
114	2950	00:08:47	96.45%	0.4601	1.0000e-04	
116	3000	00:08:56	96.21%	0.6478	1.0000e-04	
118	3050	00:09:05	96.57%	0.5892	1.0000e-04	
120	3100	00:09:13	96.70%	0.4477	1.0000e-04	
122	3150	00:09:22	96.27%	0.5793	1.0000e-04	
124	3200	00:09:31	96.71%	0.5291	1.0000e-04	
125	3250	00:09:40	96.24%	0.5906	1.0000e-04	
127	3300	00:09:48	96.47%	0.6176	1.0000e-04	
129	3350	00:09:57	96.73%	0.5578	1.0000e-04	
131	3400	00:10:05	96.74%	0.4506	1.0000e-04	
133	3450	00:10:14	96.64%	0.5352	1.0000e-04	
135	3500	00:10:23	96.38%	0.4733	1.0000e-04	
137	3550	00:10:31	96.53%	0.4890	1.0000e-04	
139	3600	00:10:40	96.39%	0.4676	1.0000e-04	
141	3650	00:10:49	96.28%	0.6300	1.0000e-04	
143	3700	00:10:57	96.67%	0.5790	1.0000e-04	
145	3750	00:11:06	96.74%	0.4543	1.0000e-04	
147	3800	00:11:14	96.27%	0.5624	1.0000e-04	
149	3850	00:11:23	96.75%	0.5201	1.0000e-04	
150	3900	00:11:32	96.21%	0.5804	1.0000e-04	

La formation réseau a duré environ et 10 minutes car notre ordinateur il ne dispose pas de GPU (unité de traitement graphique). Cette ressource aurait pu tomber en panne dans une large mesure, le temps de traitement nécessaire pour former notre modèle.

Malgré cela, nous avons atteint un taux de perte de 1% et un taux de précision de 96.21%. Avec ces pourcentages nous pouvons dire que notre réseau de neurones a été bien entraîné et devrait donner des résultats satisfaisants.

## 4.7 Conclusion

Nous avons présenté dans ce chapitre les différentes étapes de conception et implémentez notre application de segmentation d'images, pour cela on a créé un modèle et nous avons fait des tests, les résultats obtenues sont évolués par des critères en termes de précision et d'erreur. L'implémentation que nous avons proposée permet d'introduire les outils de développement utilisés et divers tests des tumeurs.

## Conclusion générale

Les cas du cancer du sein augmentent chaque jour, dans le monde entier et personne n'est à l'abri de cette maladie. A partir d'un certain âge, un diagnostic et un bilan annuel sont nécessaires. Parmi les méthodes de diagnostic, on trouve l'imagerie par résonance magnétique (IRM).

Même si l'imagerie par résonance magnétique est un examen de confirmation et de certitude, il reste cependant fastidieux au diagnostic pour les radiologues et les médecins, en particulier pour les petites lésions ou petites masses cancéreuses non observables, à l'œil nu.

Le travail que nous avons réalisé dans le cadre de ce mémoire porte essentiellement sur la détection des maladies avec le traitement d'image. Et on a discuté des notions fondamentales de l'apprentissage les plus populaires, des réseaux de neurones en général et des réseaux de neurones convolutionnels en particulier. Nous avons introduit ces réseaux de neurones convolutionnels en présentant les différents types de couches utilisées dans la classification.

On a implémenté le réseau neurones convolutifs et on a fait un test et afficher à la fin les résultats.

L'implémentation a été faite avec Matlab pour faciliter la tâche de création de nos modèles et pour l'accélération du training.

Notre système de classification est constitué de réseaux neuronaux convolutifs capable de détecter la présence ou l'absence du cancer du sein, en un temps réduit avec la meilleure exactitude obtenue, de l'ordre de 96.21%. Avec ces pourcentages nous pouvons dire que notre réseau de neurones a été bien entraîné et devrait donner des résultats satisfaisants.

# Bibliographie

[1]<https://astronomie-pratique.com/etoile-a-neutrons/>

[2]<http://tecfa.unige.ch/themes/FAQ-FL/resolution/resolution.html>

[3][https://www.researchgate.net/figure/True-color-24-bit-jellybean-image-and-its-segmented-image-of-only-12-colors\\_fig1\\_235923374](https://www.researchgate.net/figure/True-color-24-bit-jellybean-image-and-its-segmented-image-of-only-12-colors_fig1_235923374)

[4]Hadjila Feth Allah et Bouabdallah Réda, Reconnaissance des visages en utilisant les réseaux de neurones. Mémoire d'ingénieur. Université de Tlemcen. 2003.

[5]<https://briques-de-geomatique.readthedocs.io/fr/latest/segmentation-images.html>.

[6]<https://blog.digitalcook.fr/traitement-d-image-numerique/>.

[7]<http://www.telecom.ulg.ac.be/teaching/notes/totali/elen016/node142.html>

[8] Lu Hongtao; Zhang Qinchuan Applications of Deep Convolutional Neural Network in Computer Vision Department of Computer Science and Engineering, Shanghai Jiao Tong University

[9]<https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-lesreseaux-de-neurones-artificiels>

[10]<https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>

[11] <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/>

[12] Numan Munir - convolutional neural network for ultrasonic weldment flaw classification in noisy conditions

[13]<https://towardsdatascience.com/a-comprehensive-guide-to-convolutionalneural-networks-the-eli5-way-3bd2b1164a53>

**[14]** Découvrez les différentes couches d'un CNN, NEDJAH Kimia ingénieure en Machine Learning et vision par l'ordinateur le 05 mai 2021

**[15]** <https://www.jobintree.com/dictionnaire/definition-matlab-915.html>

**[16]**.<https://blog.paperspace.com/unet-architecture-image-segmentation/>