

**République Algérienne Démocratique et Populaire**  
**Ministère de l'enseignement supérieur et de la**  
**Recherche scientifique**

**UNIVERSITÉ SAAD DAHLEB DE BLIDA**

**1**

**Faculté des sciences**

**Département D'informatique**

**MÉMOIRE DE MASTER**

**En Informatique**

**Option : Systèmes Informatique et Réseaux**

**THÈME :**

**Segmentation sémantique de la colonne vertébrale par les**  
**réseaux de neurones profonds**

Réaliser par :

Koudji Badr-Eddine

Meknaci Fahd

Encadré PAR :

Benblidia Nadjia &

Reguieg Fatma Zohra

Devant le jury composé de :

Madame Cheriguene Soraya

Madame Ferdi Imene

# Remerciement

Nous tenons à remercier.

En premier lieu le bon Dieu de nous avoir donné la force et le courage pour réaliser à terme ce travail.

Nous tenons à remercier toutes les personnes commençons par nos parents, nos familles par leurs sacrifices pour nous fournir les meilleures conditions de travail, ainsi nos amis qui ont contribué au succès de notre travail et qui nous ont aidé lors de la rédaction de ce mémoire.

Nous remercierons nos promotrices Mme Benblidia Nadjia et Reguieg

Fatma Zohra pour nous avoir Proposé ce thème,

Nous leurs sommes très

reconnaissants pour ses remarques et conseils.

En fin nos remerciements s'adressent aussi aux membres du Jury pour nous avoir fait l'honneur d'examiner notre travail

# Résumé

Le mal de dos, le mal du siècle comme beaucoup de gens le décrivent, est un terme général pour une maladie potentiellement grave et l'un des problèmes médicaux les plus courants dans le monde. Il peut se produire à n'importe quel endroit au niveau de la colonne vertébrale. Pour identifier l'origine d'une douleur et déterminer si un traitement est nécessaire, les experts dans ce domaine se basent sur l'analyse des images médicales telles que l'IRM et CT-scan pour identifier les zones endommagées ou les anomalies.

Un examen de radiologie classique est une tâche compliquée et coûteuse en temps précieux pour le malade et le médecin. De plus, dans certaines situations, l'identification de ces anomalies à l'œil nu n'est pas toujours évidente, ce qui nécessite l'application de certaines techniques de traitement d'image afin de guider l'expert à réaliser un bon diagnostic. Parmi les techniques les plus employées dans ce domaine nous citons la segmentation d'images qui permet de délimiter et d'identifier les zones d'intérêt. Une segmentation précise et robuste des structures est une condition préalable au diagnostic assisté par ordinateur et à l'identification des anomalies. Les approches utilisées pour la segmentation des images médicales restent limitées de point de vue performance et nécessitent l'intervention d'un expert humain. Récemment, les réseaux de neurones convolutifs (RNC) ont montré des performances exceptionnelles surtout dans le domaine de traitement d'images médicales.

Notre travail vise à proposer une nouvelle approche pour la segmentation des vertèbres et des disques intervertébraux de la partie lombaire de la colonne vertébrale basée sur la combinaison des réseaux de neurones convolutifs avec la segmentation par WATERSHED et détection de contours appliquée sur des images IRM 3D. La technique proposée utilise les images traitées par le réseau de neurones comme initialisation pour l'algorithme de WATERSHED afin de raffiner la segmentation initiale. L'approche a été évaluée quantitativement sur deux bases de données différentes proposées par notre promotrice pour la segmentation des vertèbres et des disques.

**Mots-clés** : Colonne vertébrale, image résonance magnétique, segmentation de l'image, réseau de neurones convolutif (RNC), Ligne partage des eaux (LPE).

# Abstract

Back pain, the pain of the century as many people describes it, is a general term for a potentially serious disease and one of the most common medical problems in the world. It can occur anywhere in the spine. To identify the cause of pain and determine if treatment is needed, experts in the field rely on analysis of medical images such as MRI and CT scans to identify damaged areas or abnormalities.

A conventional radiology examination is a complicated and time-consuming task for both the patient and the physician. Moreover, in some situations, the identification of these abnormalities with the naked eye is not always obvious, which requires the application of certain image processing techniques in order to guide the expert to make a correct diagnosis. Among the most common techniques used in this field is image segmentation, which allows the delineation and identification of areas of interest. Accurate and robust segmentation of structures is a prerequisite for computer-aided diagnosis and identification of anomalies. The approaches used for the segmentation of medical images remain limited in terms of performance and require the intervention of a human expert. Recently, convolutional neural networks (CNN) have shown exceptional performances especially in the field of medical image processing.

Our work aims at proposing a new approach for the segmentation of vertebrae and intervertebral discs of the lumbar part of the spine based on the combination of convolutional neural networks with WATERSHED segmentation and edge detection applied on 3D MRI images. The proposed technique uses the images processed by the neural network as initialization for the WATERSHED algorithm to refine the initial segmentation. The approach has been quantitatively evaluated on two different databases proposed by our sponsor for vertebrae and disc segmentation.

**Keywords:** Spine, magnetic resonance image, image segmentation, convolutional neural network (CNN), Watershed.

# Table des matières

Introduction générale.....

## Chapitre 1 : Contexte médicale

1.	Introduction .....	1
2.	Rachis cervical.....	1
3.	Composition du rachis cervicale .....	1
4.	Lordose .....	4
4.1	Lordose cervicale .....	5
4.2	Lordose lombaire .....	7
5.	Rachis thoracique .....	9
6.	Cyphose.....	11
7.	Classification.....	15
8.	Prise en charge.....	17
9.	Traitement.....	18
10.	Examen clinique.....	20
11.	Conclusion .....	22

## Chapitre 2 : Architectures réseaux de neurones convolutionnels

1.	Introduction .....	23
2.	Réseaux de neurones convolutionnels .....	23
3.	Couches de convolution.....	26
4.	L'augmentation des données .....	31
5.	Architectures de classification.....	33
6.	Architectures de segmentation.....	39
7.	Conclusion .....	46

### Chapitre 3 : Segmentation des vertèbres et des disques intervertébraux

1.	Introduction .....	47
2.	Architecture de réseau proposée .....	47
3.	Réglage des hyperparamètres.....	49
4.	Filtrage des images.....	50
5.	Segmentation par SEUILLAGE .....	51
6.	Transformations morphologiques.....	53
6.1	Opération de dilatation .....	54
6.2	Opération d'érosion .....	54
6.3	Opération d'ouverture.....	54
6.4	Opération de fermeture .....	54
7.	Détection de contours .....	55
7.1	Lire l'image et la convertir au format Niveaux de gris <b>Error! Bookmark not defined.</b>	
7.2	Appliquer le seuillage Adaptative .....	<b>Error! Bookmark not defined.</b>
8.	Ligne de partage des eaux (LPE ou Water shed) .....	56
8.1	Algorithme .....	57
8.2	Marqueurs .....	58
8.3	Relief .....	58
8.4	Inondation .....	59
9.	Post-traitement.....	60
10.	Conclusion .....	60

### Chapitre 4 : Implémentation et développements

1.	Introduction .....	61
1.1	Étude des documents .....	61
2.	Etude conceptuelle .....	61

2.1	Cycle de développement.....	61
2.2	Méthode de modélisation .....	62
3.	Conclusion .....	67
Chapitre 5 : Mise en œuvre du système HEALTHCARE		
1.	Introduction .....	68
2.	Détails d'implémentation .....	68
3.	Outils de rédaction et de conception .....	71
4.	Outils de développement .....	72
5.	Aperçu de notre application HEALTHCARE .....	75
6.	Conclusion .....	78
	Conclusion générale et perspectives.....	79
	Bibliographie.....	81

# TABLE DE FIGURES

Figure 1.1 : Vertèbre cervicale typique vue supérieure .....	1
Figure 1. 2 : Vertèbre cervicale typique vue antérieure .....	2
Figure 1. 3 : Vertèbre cervicale typique vue antérolatérale .....	2
Figure 1. 4 : Atlas + axis .....	3
Figure 1. 5 : Atlas + axis vue antérolatérale .....	3
Figure 1. 6 : Rachis intérieur .....	4
Figure 1. 7 : Types de lordose .....	4
Figure 1. 8 : Différence entre la scoliose la cyphose et la lordose .....	5
Figure 1. 9 : Lordose cervicale .....	5
Figure 1. 10 : vu supérieur de la vertèbre thoracique type .....	10
Figure 1. 11 : Cyphose dorsale .....	11
Figure 1. 12 : Visualisation de la cyphose avec Angle Cobb .....	14
Figure 1. 13 : cyphose congénitale chez les enfants .....	15
Figure 1. 14 : Maladie de Scheuermann.....	16
Figure 1. 15 : Cyphose régionale post-traumatique.....	17
Figure 1. 16 : Résultat du traitement non chirurgical .....	19
Figure 1. 17 : Résultat du traitement non chirurgical .....	20
Figure 1. 18 : Diagnostic médical par observation.....	21
Figure 2. 1 : Neurone biologique et son modèle mathématique .....	24
Figure 2. 2 : Convolution avec un filtre de taille 3x3.....	27
Figure 2. 3 : Convolution avec un filtre de taille 3x3.....	28
Figure 2. 4 : Différents types de Pooling 2x2 avec un pas de 2 .....	29
Figure 2. 5 : Objet avant et après n cisaillement .....	32
Figure 2. 6 : Architecture LE-NET 5.....	34
Figure 2. 7 : La progression de la performance de classement.....	34
Figure 2. 8 : Diagramme de l'architecture ALEX-NET .....	36
Figure 2. 9 : Architecture VGG .....	36
Figure 2. 10 : Table de configuration VGG NET .....	37
Figure 2. 11 : Architecture RES-NET.....	38
Figure 2. 12 : Architecture RES-NET.....	38
Figure 2. 13 : Partie convolutive (encodeur) de l'architecture VGG-16 .....	40



Figure 2. 14 : Architecture U-net .....	44
Figure 3. 1 : Les couches du modèle U-NET.....	49
Figure 3. 2 : LOI GAUSSIENNE .....	51
Figure 3. 3 : Seuillage simple d'un histogramme.....	51
Figure 3. 4 : Seuillage multiple .....	52
Figure 3. 5 : Illustration du seuillage adaptatif .....	53
Figure 3. 6 : Morphologique sur le rachis .....	55
Figure 3. 7 : Gradient sur le rachis .....	57
Figure 3. 8 : Marqueurs sur le rachis.....	58
Figure 3. 9 : Gradient appliqué sur le rachis.....	59
Figure 3. 11 : Marqueurs .....	59
Figure 4. 1 : Développement Itératif Et Incrémental .....	62
Figure 4. 2 : Diagramme de cas d'utilisation.....	63
Figure 4. 3 : Authentification .....	64
Figure 4. 4 : Ajoute les données.....	64
Figure 4. 5 : Segmentation de l'image .....	66
Figure 4. 6 : Prédiction.....	66
Figure 4. 7 : Diagramme de Class .....	66
Figure 5. 1 : Différentes segmentation obtenue.....	70
Figure 5. 2 : La précision et la perte de notre modèle.....	71
Figure 5. 3 : Authentification .....	76
Figure 5. 4 : Connection .....	76
Figure 5. 5 : Menu principal .....	77
Figure 5. 6 : Téléchargement des données .....	77

## Table d'abréviation

AINS	ANTI-INFLAMMATOIRES NON STEROÏDIENS
BSD	BERKELEY SOFTWARE DISTRIBUTION LICENSE
CIE	COMMISSION INTERNATIONALE DE L'ECLAIRAGE
CRF	CONDITIONAL RANDOM FIELDS
CV	COLONNE VERTEBRALE
DIV	DISQUES INTER VERTEBRES
HSV	HUE, SATURATION, AND VALUE
ILSVRC	IMAGENET LARGE SCALE VISUAL RECOGNITION CHALLENGE
IRM	IMAGERIE PAR RESONANCE MAGNETIQUE
LPE	LIGNE PARTAGE DES EAUX
MNIST	MODIFIED NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY
NOSQL	NOT ONLY STRUCTURED QUERY LANGUAGE
RELU	UNITE RECTIFIEE LINEAIRE
RNC	RESEAU DE NEURONES CONVOLUTIVE
RVB	RED, GREEN, BLUE
UML	UNIFIED MODELING LANGUAGE

# Introduction générale

La lordose et la cyphose idiopathique est une déformation tridimensionnelle importante de la colonne vertébrale dont les causes sont inconnues.

Cette déformation entraîne une torsion et une courbure anormales de la colonne vertébrale dont les conséquences se manifestent par des déformations morphologiques qui varient selon sa gravité.

Nous parlons de douleurs rachidiennes chroniques, inconfort, mobilité réduite, diminution de la qualité de vie en cas de lordose et la cyphose sévère.

Dans de telles circonstances, un traitement chirurgical est préconisé. La chirurgie minimalement invasive est une technique qui limite le traumatisme opératoire en réduisant l'incision à quelques centimètres. Sa mise en pratique vise à accélérer la récupération post-opératoire, réduire la douleur et le risque d'infections. Par contre, la visibilité du chirurgien est considérablement réduite. Les systèmes de navigation par ordinateur représentent une solution intéressante pour guider le chirurgien dans sa tâche.

La discectomie par thoracoscopie est une procédure chirurgicale minimalement invasive du rachis employé dans le traitement de la lordose et la cyphose.

Elle consiste à réaliser une résection de certains DIVs pour relâcher la pression créée par la torsion de la colonne vertébrale. Ensuite, des vis sont placées sur les vertèbres qui vont créer un mouvement mécanique qui va redresser la colonne de manière continue durant plusieurs mois.

Toutefois, la segmentation des vertèbres et des structures voisines en IRM reste une tâche difficile, ce qui est principalement dû au mauvais contraste entre les os et les tissus mous. De plus, l'IRM tend à générer des images dont l'intensité est non homogène.

La littérature propose plusieurs méthodes pour la segmentation des DIVs et CVs à partir d'IRM. Toutefois, ces approches sont pour la plupart destinées à des contextes d'application différents de la lordose et la cyphose.

Le changement de morphologie dû à la lordose et la cyphose fait que ces approches ne prennent pas en considération la déformation de ces deux structures et ne sont donc pas assez robustes pour effectuer leur segmentation. En parallèle, l'analyse d'images médicales a grandement profité de l'émergence de l'intelligence artificielle

et plus particulièrement de l'apprentissage profond et sa capacité à résoudre des problèmes complexes de reconnaissance de formes.

Cette capacité est conditionnelle à la disponibilité d'un grand nombre de données annotées, ce qui est très peu évident à obtenir dans le contexte médical et les données de patients lordosiques et cyphotiques en IRM ne font pas exception à la règle.

### **Plan de mémoire**

Ce mémoire s'articule en plusieurs chapitres, Tout d'abord, une première partie, permettant de mieux définir le contexte de ces travaux, est consacrée à quelques brefs rappels d'anatomie du Rachis chez le patient sain et chez le patient lordosique et cyphotique.

Ensuite nous passons aux méthodes de segmentation des vertèbres et inter vertèbres qui est un paradigme d'interaction qui est né de la volonté de fusionner les capacités du traitement informatique et l'environnement physique.

L'objectif est de parvenir à rompre la frontière entre la vision d'ordinateur et le monde réel, qui empêche l'entrelacement simple et transparent des informations issues du monde réel avec celles issues du monde informatique.

Dans un 3eme point, nous parlerons de réseaux de neurones profonds, on étudie les différentes architectures de segmentation et de classification des images médicales. Un autre objectif de notre travail est d'établir des éléments utiles à la conception et à la réalisation d'une application web, un système interactif qui est destinée aux médecins de l'hôpital, pour une aide au diagnostic des patients atteints de lordose et de cyphose utilisant les données fournies par notre promotrice.

Pour mener à bien notre travail, nous l'avons organisé comme suit :

- Le chapitre 1 est consacré au contexte médical.
- Le chapitre 2 est présente les architectures de réseaux de neurones.
- Le chapitre 3 dédié à l'étude des méthodes de segmentation des vertèbres et des disques intervertébraux.
- Le chapitre 4 est Implémentation et développement.
- Le chapitre 5 décrit mise en œuvre du système HEALTHCARE.

Ce mémoire sera finalisé par une conclusion générale reprenant les principaux points abordés et, en exposant certaines perspectives pour l'amélioration du travail présent.



## **Chapitre 1 : Contexte Médical**



## 1. Introduction

Dans ce chapitre, nous couvrirons toutes les informations de manière claire et simplifiée sur les composants et la méthode de division de la colonne vertébrale humaine et sur les maladies qui y sont liées.

Nous expliquerons également la majorité des études liées à ces maladies qui sont la lordose et la cyphose à partir des causes et des symptômes.

Ainsi que des différentes solutions médicales et paramédicales pour chacun de ces derniers.

## 2. Rachis cervical

Le rachis cervical correspond à un ensemble de vertèbres situé entre le crâne et les vertèbres dorsales (ou thoraciques). Il est très mobile et protège la portion haute de la moelle épinière [1].

## 3. Composition du rachis cervicale

Il est constitué de 7 vertèbres qui sont empilées et attachées par les disques intervertébraux et des ligaments très résistants [1].

On voit dans les figures suivantes des vertèbres typique avec différent vues :




Figure : 1.1 Vertèbre cervicale typique vue supérieure [2]




Figure 1. 2 : Vertèbre cervicale typique vue antérieure [2]




Figure 1. 3 : Vertèbre cervicale typique vue antérolatérale [2]

On distingue le rachis cervical supérieur du rachis cervical inférieur.

Le rachis cervical supérieur compte deux vertèbres C1 et C2, aussi appelées l'atlas et l'axis. L'anatomie de ces vertèbres est très particulière. L'atlas compte un arc antérieur, un arc postérieur et deux masses latérales. L'axis présente un corps vertébral, une dent appelée odontoïde et un arc postérieur (pédicules, isthme, lames et épineuses.). La pathologie de ces étages est peu fréquente mais parfois une arthrose sévère entre ces deux vertèbres peut aboutir à un syndrome douloureux de type névralgie d'Arnold [3].




Figure 1. 4 : Atlas + axis [3]

Avant de passer au point suivant on va voir quelque figure de l'atlas et l'axis en commun :




Figure 1. 5 : Atlas + axis vue antérolatérale [2]

Le rachis cervical inférieur compte 5 vertèbres nommées de C3 à C7.

Les nerfs à destination des membres supérieurs sortent à ce niveau. Il y a 8 nerfs cervicaux pour 7 vertèbres cervicales et chaque nerf sort au-dessus de la vertèbre du même numéro.

Par exemple, le nerf C6 sort au-dessus de la vertèbre C6, c'est à dire à l'étage C5-C6.

Le nerf C8 sort quant à lui entre la vertèbre C7 et la première vertèbre thoracique T1.



Les nerfs émergent de la colonne vertébrale par un trou situé entre deux vertèbres contiguës, appelé foramen. Ils peuvent être menacés à ce niveau par une hernie discale ou par de l'arthrose (sténose disco-ostéophytique lié à l'uncus vertébral) [1].



Figure 1. 6 : Rachis intérieur [1]

## 4. Lordose

Voici ci-dessus une image qui résume la lordose (les deux types) avec la cyphose. La lordose ou « concavité » constitue une courbure au niveau de la colonne vertébrale, Chez les personnes atteintes, la partie centrale du dos devance les deux extrémités [12], Vue de profil, la colonne vertébrale présente trois courbures naturelles : on appelle lordose cervicale, le creux au niveau du cou, cyphose, l'arrondi du haut du dos, et lordose –ou lordose lombaire, la cambrure du creux des reins. Lorsque l'une des lordoses est excessive, on parle d'hyperlordose cervicale ou lombaire. L'hyperlordose pousse alors les vertèbres à s'incliner de plus en plus en arrière et modifie l'équilibre général de la colonne [15].




Figure 1. 7 : Types de lordose [3]

## 4.1 Lordose cervicale

Il s'agit d'une cambrure physiologique antérieure de la colonne vertébrale au niveau du cou, le sommet de la cambrure est en avant des vertèbres justes derrière la trachée. C'est une posture naturelle, comme la lordose lombaire qui est dans le même sens et la cyphose dorsale qui elle est à courbure postérieure [4].

On voit dans la page suivante la différence entre lordose et la cyphose et la scoliose :




Figure 1. 8 : Différence entre la scoliose la cyphose et la lordose [4]




Figure 1. 9 : Lordose cervicale [5]

## 4.1.1 Causes de lordose cervicale

Les causes sont organisées en deux [6] :

**Les causes primaires** sont la malformation congénitale.

**Les causes secondaires** biomécaniques c'est à dire les facteurs fonctionnels annexes qui influencent les mouvements des vertèbres cervicales :

- Syndrome des processus articulaires postérieurs (douleur ponctiforme, souvent latéralisée et aggravée en extension et inclinaison homolatérale de tête).
- Contracture des muscles du cou (spinaux, scalènes, trapèze, élévateur de la scapula etc. ...) entraînant une diminution des amplitudes articulaires de référence du rachis cervical.
- Accumulation de tissu adipeux plus ou moins dense au niveau de la charnière cervico-dorsale (bosse de bison).
- Hypercyphose thoracique (par compensation celle-ci peut entraîner des cervicalgies).

## 4.1.2 Symptômes de lordose cervicale

- Douleurs musculaires chroniques le long du rachis cervical et dorsal pouvant être mécaniques (réveillées à un ou plusieurs mouvement) ou inflammatoires (présentes à tous les mouvements, réveillant la nuit et mettant plus de 30 minutes à disparaître au réveil) et souvent aggravées par le sport.
- Nuque raide .
- Déformations vers l'arrondissement (hyperlordose) ou l'effacement (méplat) de cette lordose.
- Irradiations (sensations de trajet électriques, impulsifs ou non) vers la tête, la nuque, le membre supérieur survenant essentiellement lors d'un ou d'une combinaison de mouvements du cou. Ces irradiations peuvent être ressenties jusque dans les doigts.
- Paresthésies (sensations diffuses dans les membres comme des fourmillements ou un engourdissement, des brûlures etc. ...).
- Perte plus ou moins importante de la sensibilité intéressant les métamères innervés par les racines cervicales concernées.

## 4.2 Lordose lombaire

L'hyperlordose lombaire est définie par une exagération de la courbure du bas du dos au niveau des cinq vertèbres lombaires. Elle peut être constitutionnelle ou déclenchée par une pathologie ou une cause annexe à l'image d'une mauvaise posture persistante. L'hyperlordose lombaire peut survenir à tout âge, avec une prévalence accrue chez les seniors. Des exercices de musculation et de souplesse pourront la prévenir ou atténuer ses symptômes. [7].

### Types d'hyperlordoses lombaires :

L'hyperlordose lombaire présente deux types distincts [7] :

- **Constitutionnelle**, elle correspond à un morphotype familial.
- **Secondaire**, elle est déclenchée par une cause annexe.

### 4.2.1 Causes d'hyperlordose lombaire

Les causes de l'hyperlordose lombaire secondaire sont nombreuses. Elles comprennent [7] :

- Une hypotonie abdominale en phase pré pubertaire.
- La compensation d'une cyphose dorsale anormalement convexe –un dos rond.
- Une croissance trop rapide du squelette de l'enfant.
- Une dysplasie –malformation ou déformation– des articulations pelviennes.
- Une achondroplasie –nanisme d'origine héréditaire et congénitale
- Une mauvaise posture persistante.
- Des néoplasmes –tumeurs cancéreuses– au niveau de la colonne vertébrale.
- Une hernie intervertébrale.
- Une ankylose ou la diminution, voire le blocage, des mouvements d'une articulation naturellement mobile.
- Une luxation bilatérale de l'articulation fémorale.
- Un ostéochondrose –anomalie de la croissance de l'os et du cartilage– dans le bas du dos.
- Une maladie infectieuse.
- Une maladie neurologique.
- Le rachitisme –maladie de la croissance et de l'ossification.

- La maladie de Kashin-Bek–maladie ostéoarticulaire permanente et invalidante qui touche le cartilage de croissance et articulaire des os longs.

## **4.2.2 Facteurs favorisant l'hyperlordose lombaire**

Les facteurs susceptibles de favoriser l'hyperlordose sont [7] :

- La grossesse.
- L'embonpoint ou le surpoids.
- Une mauvaise position persistante.
- Des blessures au dos.
- Le port prolongé ou répété de chaussures à talons hauts.
- Une faiblesse musculaire des muscles centraux –sangle abdominale, lombaires.
- L'ostéoporose, avec la perte de densité osseuse.

## **4.2.3 Symptômes d'hyperlordose lombaire**

Il y a des cas où il n'y a pas de symptômes, d'autres fois il y a plusieurs symptômes qui sont les suivants [7] :

- L'engourdissements dans les membres inférieurs.
- Douleurs ressenties dans les bras et les jambes.
- Inflammations dans certaines parties du corps : haute du dos, bas du dos.

## **4.2.4 Diagnostic médicale de lordose cervicale**

Le diagnostic d'hyperlordose cervicale est clinique, La réalisation d'une radiographie c'est suffisant mais bien faire un scanner c'est beaucoup mieux mais parfois l'IRM OU TDM est plus nécessaire [7].

## **4.2.5 Traitement de lordose cervicale**

Le traitement il sera comme suit [7] :

- Des antalgiques et des anti-inflammatoires durant une courte période.
- Des séances de kinésithérapie en parallèle avec les médicaments.
- Les exercices de renforcement musculaire.

## **4.2.6 Diagnostique de lordose lombaire**

Le diagnostic d'hyperlordose lombaire est posé après un examen médical approfondi qui repose d'abord sur l'observation attentive de la posture et de la colonne par le médecin afin d'identifier les zones de déformations avec précision. L'hyperlordose lombaire sera ensuite confirmée par une imagerie de la colonne vertébrale (radio, scanner, IRM ou TDM) [7].

## **4.2.7 Traitement d'hyperlordose lombaire**

Le traitement d'hyperlordose lombaire sera prescrit cas par cas, mais les symptômes seront atténués par :

Le prise de certains médicaments d'antalgique, de myorelaxants, des anti-inflammatoires en dac de douleurs aiguës.

Un programme de perte de poids en cas d'embonpoint.

Des séances de kinésithérapie visant à développer la musculature et la souplesse [7].

## **5. Rachis thoracique**

IL comporte 12 vertèbres (T1 à T12) long de 28 cm, il est peu mobile.

### **5.1 Constitution de vertèbre thoracique**

Il se constitue de [8] :

- **Corps vertébraux** : (1) Cylindrique avec 4 facettes articulaires costal supérieur et Inférieures (3).
- **Foramen vertébral** : Circulaire (10).
- **Pédicules (4)** : Bord inférieur très échancré sur une vue latérale.
- **Processus articulaire.**
- **Supérieur (7).**
- **Lame (8)** : quadrilatère.
- **Processus épineux** : Incliner uni- tuberculé (9).
- **Processus transverses (5)** : Avec une facette articulaire costal transversaire.

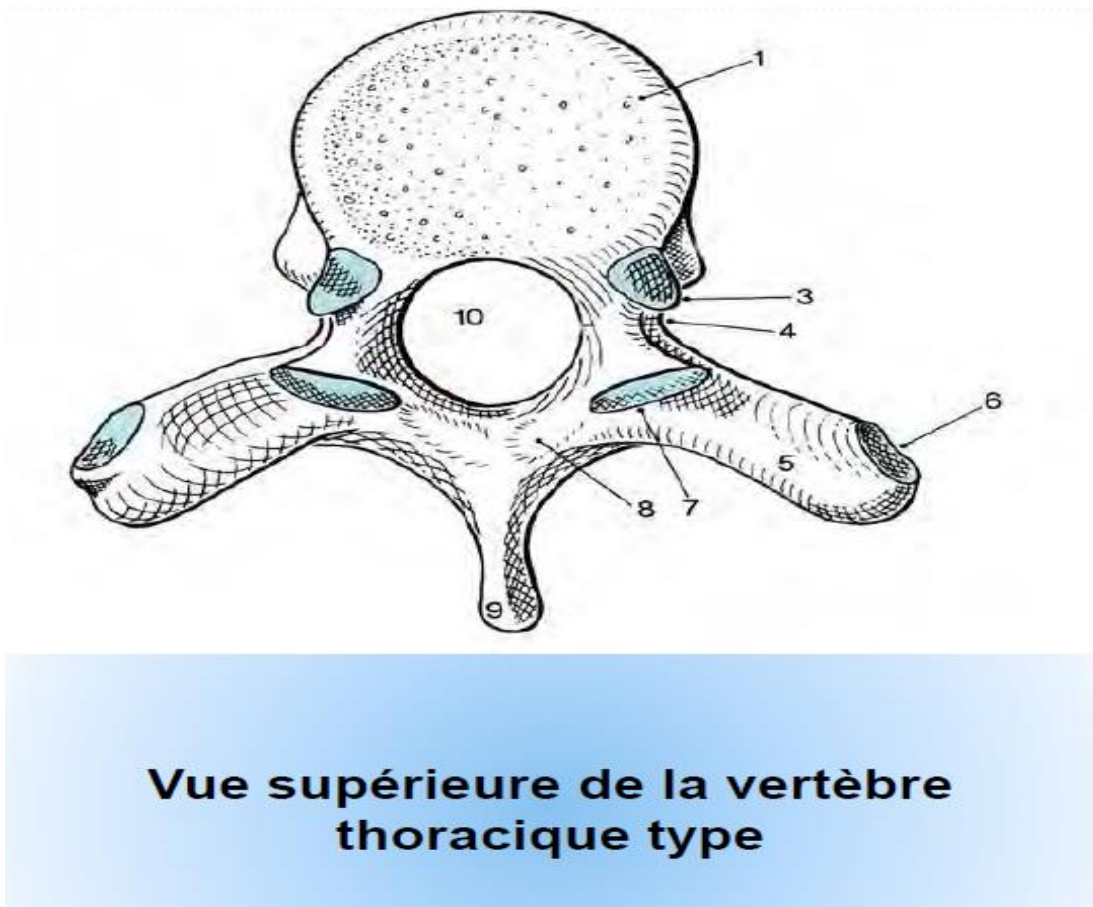


Figure 1. 10 : vu supérieur de la vertèbre thoracique type [8]

## 5.2 Variation des vertèbres

### 1ere vertèbre thoracique :

Processus uncinés supérieure (face crâniale) sur le corps facette articulaire costal articulaires costal supérieur pour la première côte Processus épineux plus horizontal.

### 10ème vertèbre thoracique :

Deux facettes articulaire costal crâniale pour la 10<sup>ème</sup> côte uniquement.

### 11<sup>e</sup> et 12<sup>e</sup> vertèbre thoracique :

2 facettes articulaires costal sur le corps aucune facette articulaire sur le processus transverse.[8]

En effet le thorax est **une cage** (la cage thoracique). Chaque vertèbre s'articule avec une côte de chaque côté fixé en avant au sternum. Le rôle de cette cage est de protéger les organes (cœur et poumon), le rachis thoracique protège la moelle épinière thoracique qui distribue les nerfs affectés à ces organes.



En raison de sa faible mobilité, cette portion de la colonne vertébrale est plus rarement exposée aux manifestations dégénératives, les disques y sont naturellement très fins. La moelle épinière thoracique est cependant extrêmement fragile car elle est très mal vascularisée. Les lésions graves à ce niveau sont souvent peu réversibles et responsables d'une perte ou d'une diminution de la fonction des membres inférieurs (paraplégie).

**Pathologies** du rachis dorsale sont :

- **Cyphose**
- **Lordose**

## 6. Cyphose

La cyphose dorsale survient plutôt à l'adolescence. Elle est parfois réversible grâce une activité physique et à des exercices ciblés.



Figure 1. 11 : Cyphose dorsale [9]

### 6.1 Définition et description de la pathologie

La cyphose dorsale désigne une exagération de la courbure du rachis dorsal dans le plan sagittal antéro-postérieur. En clair, il s'agit d'une déformation du dos provoquée par la courbure excessive de la colonne vertébrale entre la 1ère et la 12ème vertèbre [10].



## 6.2 Symptômes

Chez une personne qui souffre de cyphose dorsale, le dos semble voûté. On peut observer une bosse entre la base de la nuque et le milieu du dos. La personne se tient penchée en avant. La cyphose dorsale peut être douloureuse car elle conduit les muscles posturaux à travailler en permanence [10].

## 6.3 Causes

Il existe 2 types de cyphose dorsale : la cyphose dorsale régulière, responsable d'une courbure étendue sur toutes les vertèbres, et la cyphose dorsale non-régulière, nettement moins fréquente, qui se caractérise par un angle aigu (le dos fait réellement une bosse et la personne semble vraiment très penchée en avant).

La cyphose dorsale régulière est la plus fréquente : chez l'adolescent, elle est souvent en lien avec une attitude apathique et sédentaire. L'adolescent est peu musclé, fait peu de sport, se tient " tassé " sur sa chaise, a souvent la tête penchée vers son téléphone portable, sa tablette ou son ordinateur... Elle peut alors être corrigée, car il n'y a pas de modification de la morphologie des vertèbres. Au contraire, lorsque la cyphose dorsale régulière est provoquée par une pathologie congénitale ou non (maladie de Scheuermann ou dystrophie rachidienne de croissance, par exemple), par un traumatisme ou par une tumeur (une tumeur osseuse, par exemple, c'est heureusement très rare), elle n'est pas réductible, idem pour la cyphose dorsale non-régulière qui n'est pas réversible, on peut alors proposer de la rééducation ou des solutions orthopédiques, comme le port d'un corset, pour éviter une aggravation de la courbure dorsale [10].

## 6.4 Types de cyphose

Il existe plusieurs types de cyphose. Les trois qui affectent le plus souvent les enfants et les adolescents sont :

- Cyphose **posturale**
- Cyphose de **Scheuermann**
- Cyphose **congénitale**

## 6.4.1 Cyphose posturale

La **cyphose posturale**, le type de cyphose le plus courant, devient généralement perceptible à l'adolescence. Il se manifeste cliniquement par une mauvaise posture ou un affaissement, mais n'est pas associé à de graves anomalies structurales de la colonne vertébrale.

La courbure causée par la cyphose posturale est généralement ronde et lisse et peut souvent être corrigée par le patient lorsqu'on lui demande de « se tenir droit ».

La **cyphose posturale** est plus fréquente chez les filles que chez les garçons. Elle est rarement douloureuse et, comme la courbe ne progresse pas, elle n'entraîne généralement pas de problèmes dans la vie adulte [11].

## 6.4.2 Cyphose de Scheuermann

La **cyphose de Scheuermann** doit son nom au radiologue DANOIS qui a le premier décrit la maladie.

Comme la cyphose posturale, la cyphose de Scheuermann devient souvent apparente au cours de l'adolescence. Cependant, la cyphose de Scheuermann peut entraîner une déformation significativement plus sévère que la cyphose posturale, en particulier chez les patients minces.

La cyphose de Scheuermann est causée par une anomalie structurale de la colonne vertébrale. Chez un patient atteint de cyphose de Scheuermann, une radiographie de côté montrera que, plutôt que la forme rectangulaire normale, plusieurs vertèbres consécutives ont une forme plus triangulaire. Cette forme irrégulière amène les vertèbres à se coincer vers l'avant de la colonne vertébrale, diminuant l'espace disque normal et créant une courbure avant exagérée dans le haut du dos [11].





Figure 1. 12 : Visualisation de la cyphose avec Angle Cobb [12]

La courbe provoquée par la cyphose de Scheuermann est généralement nette et angulaire. Il est également rigide et rigide. Contrairement à un patient atteint de cyphose posturale, un patient atteint de cyphose de Scheuermann n'est pas capable de corriger la courbe en se tenant droit.

La cyphose de Scheuermann affecte généralement la colonne thoracique, mais se développe occasionnellement dans la colonne lombaire (inférieure). La maladie est plus fréquente chez les garçons que chez les filles et cesse de progresser une fois la croissance terminée.

La cyphose de Scheuermann peut parfois être douloureuse. Si la douleur est présente, elle est généralement ressentie à la partie la plus élevée ou au « sommet » de la courbe. La douleur peut également être ressentie dans le bas du dos. Cela se produit lorsque la colonne vertébrale essaie de compenser le haut du dos arrondi en augmentant la courbe naturelle vers l'intérieur du bas du dos. L'activité peut aggraver la douleur, tout comme les longues périodes de position debout ou assise [11].

### 6.4.3 Cyphose congénitale

**La cyphose congénitale** est présente à la naissance. Elle survient lorsque la colonne vertébrale ne se développe pas normalement pendant que le bébé est in utero.

Les os peuvent ne pas se former comme ils le devraient ou plusieurs vertèbres peuvent être fusionnées. La cyphose congénitale s'aggrave généralement à mesure que l'enfant vieillit.

Les patients atteints de cyphose congénitale ont souvent besoin d'un traitement chirurgical à un très jeune âge pour arrêter la progression de la courbure. Plusieurs fois, ces patients auront des malformations congénitales supplémentaires qui ont un impact sur d'autres parties du corps telles que le cœur et les reins [11].



Figure 1. 13 : cyphose congénitale chez les enfants [12]

## 7. Classification

Au fil des années, il y a eu de nombreuses classifications de ces pathologies basées sur des critères différents détaillés ci-dessous.

### 7.1 Classification en fonction de l'angle Cobb

Différentes classifications angulaires existent, même si aucune d'elles ne possède une validité générale, il existe toutefois un accord sur certains seuils [13]. Cette classification se fait à l'aide de l'angle de Cobb mesuré sur la radiographie frontale.

On utilise également la technique de Cobb pour mesurer l'annulation de la cyphose thoracique (T4–T12) et de la lordose lombaire (L1-L5) qui sont aux environs de 40° de façon normale. La réductibilité de la cyphose est mesurée sur un cliché de profil en décubitus dorsal avec un billot placé sous le sommet de la cyphose. De multiples causes, congénitales ou acquises, sont responsables d'une cyphose pathologique. Chez l'enfant, on recherche une cunéiformisation des corps vertébraux (maladie de Scheuermann). Chez l'adulte, on retrouve le plus souvent des tassements vertébraux à l'origine de l'hypercyphose. La maladie de Scheuermann (ou épiphysite vertébrale

## Chapitre 1 : Contexte médical

de croissance) est une dystrophie rachidienne apparaissant au cours de la croissance et pouvant provoquer une cyphose thoracique douloureuse chez l'adolescent (garçon le plus souvent). Les anomalies radiologiques prédominent au rachi thoracique moyen et inférieur et peuvent associer [12] :

- Des anomalies morphologiques des corps vertébraux qui doivent intéresser au moins trois vertèbres contiguës :
- Un aspect irrégulier et feuilleté et/ou des hernies intra spongieuses des plateaux vertébraux.




Figure 1. 14 : Maladie de Scheuermann [15]

- Un affaissement de la partie antérieure des corps (listel marginal) : Cunéiformisations d'au moins  $5^\circ$ . Elle se mesure par l'angle formé par les tangentes aux plateaux de la vertèbre.
- Des pincements discaux.
- Une accentuation de la cyphose thoracique ( $> 50^\circ$ ).



Figure 1. 15 : Cyphose régionale post-traumatique [15]

La cyphose régionale post-traumatique est une cyphose angulaire pathologique retrouvée dans les fractures–tassements vertébraux (Figure 1.15).

C'est l'angle entre le plateau supérieur de la vertèbre sus-jacente à la fracture vertébrale et le plateau inférieur de la vertèbre sous-jacente.

## **8. Prise en charge**

La prise en charge de la cyphose va être progressive. Le patient va d'abord faire des exercices chez un kinésithérapeute afin de corriger une mauvaise attitude et soulager les douleurs, indique le spécialiste. La suite du traitement va dépendre de l'évolution. Si l'angulation reste en dessous de 60°, il n'y a pas besoin de corset. Si elle dépasse les 60° ou que les douleurs persistent même avec la kiné, il faudra alors passer au corset.

La pratique du sport est très importante dans la prise en charge de la cyphose. Les seuls sports déconseillés sont ceux que l'on pratique assis, comme l'aviron, ou certaines nages comme le papillon qui accentue la courbure du dos. Le sport est aussi très utile pour lutter contre l'hypotonie des adolescents et les aider à adopter une bonne position. D'autant plus difficile lorsqu'on passe la journée assis au collège ou au lycée et que l'on a tendance à avoir le regard baissé vers un téléphone ou une tablette.

Pour lutter contre ces mauvaises positions, le médecin recommande de s'asseoir convenablement face à son poste de travail, pieds derrière la chaise, fesses en avant et ventre contre la table. Les avant-bras doivent être posés sur la table et le poste de travail doit être placé à hauteur des yeux [11].

## **9. Traitement**

**L'objectif du traitement est d'arrêter la progression** de la courbure et de prévenir la déformation. Le médecin tiendra compte de plusieurs éléments pour déterminer le traitement de la cyphose, notamment [11] :

- L'âge et l'état de santé général de votre enfant
- Le nombre d'années de croissance restantes
- Le type de cyphose
- La gravité de la courbe

### **9.1 Traitement non-chirurgical**

**Un traitement non chirurgical** est recommandé pour les patients atteints de **cyphose posturale**. Il est également recommandé pour les patients **atteints de cyphose de Scheuermann** qui ont des courbures inférieures à 75 degrés.

Le **traitement non chirurgical** peut inclure :

**Observation** : Votre médecin peut vous recommander de simplement surveiller la courbe pour s'assurer qu'elle ne s'aggrave pas. Votre enfant peut être invité à revenir pour des visites périodiques et des radiographies jusqu'à ce qu'il soit adulte.

À moins que la courbe ne s'aggrave ou ne devienne douloureuse, aucun autre traitement n'est nécessaire.

**Thérapie physique** : Des exercices spécifiques peuvent aider à soulager les maux de dos et à améliorer la posture en renforçant les muscles de l'abdomen et du dos. Certains exercices peuvent également aider à étirer les ischio-jambiers tendus et à renforcer les zones du corps qui peuvent être affectées par un désalignement de la colonne vertébrale.

**Anti-inflammatoires non stéroïdiens (AINS)** : Les AINS, dont l'aspirine, l'ibuprofène et le naproxène, peuvent aider à soulager les maux de dos.

**Entretènement** : Un corset peut être recommandé pour les patients atteints de cyphose de Scheuermann qui sont encore en croissance.



Le type spécifique de corset et le nombre d'heures par jour qu'il doit être porté dépendra de la gravité de la courbe. Le médecin ajustera l'attelle régulièrement à mesure que la courbe s'améliore. En règle générale, l'attelle est portée jusqu'à ce que l'enfant atteigne la maturité squelettique et que sa croissance soit terminée [11].




Figure 1. 16 : Résultat du traitement non chirurgical [15]

## 9.2 Opération chirurgicale

La fusion vertébrale est essentiellement un processus de « soudage ». L'idée de base est de fusionner les vertèbres affectées afin qu'elles guérissent en un seul os solide. La fusion des vertèbres réduira le degré de courbure et, parce qu'elle élimine le mouvement entre les vertèbres affectées, peut également aider à soulager les maux de dos.

Au cours de la procédure, les vertèbres qui composent la courbe sont d'abord réalignées pour réduire l'arrondi de la colonne vertébrale. De petits morceaux d'os, appelés greffe osseuse, sont ensuite placés dans les espaces entre les vertèbres à fusionner. Au fil du temps, les os grandissent ensemble, de la même manière qu'un os cassé guérit.

Avant de placer la greffe osseuse, le médecin utilisera généralement des vis, des plaques et des tiges métalliques pour augmenter le taux de fusion et stabiliser davantage la colonne vertébrale.



La quantité exacte de fusion de la colonne vertébrale dépend de la taille de la courbe de votre enfant. Seules les vertèbres courbes sont fusionnées. Les autres os de la colonne vertébrale peuvent toujours bouger et aider à la flexion, au redressement et à la rotation [11].




Figure 1. 17 : Résultat du traitement non chirurgical [15]

## 10. Examen clinique

Une cyphose légère passe souvent inaperçue jusqu'à un dépistage de la scoliose à l'école, ce qui incite à une visite chez le médecin. Cependant, si des changements dans le dos du patient sont perceptibles, cela est généralement assez troublant pour les parents et l'enfant. Le souci de l'apparence esthétique du dos de l'enfant est souvent ce qui amène la famille à consulter un médecin.

Le médecin commencera par prendre ses antécédents médicaux et posera des questions sur l'état de santé général et les symptômes de votre enfant. Il ou elle examinera ensuite le dos de votre enfant, en appuyant sur la colonne vertébrale pour déterminer s'il y a des zones de sensibilité.

Dans les cas plus graves de cyphose, l'arrondi du haut du dos ou une bosse peuvent être clairement visibles. Dans les cas plus bénins, cependant, la maladie peut être plus difficile à diagnostiquer.

Pendant l'examen, le médecin demandera à l'enfant de se pencher en avant avec les deux pieds joints, les genoux tendus et les bras pendants.

Ce test, appelé « test de flexion avant d'Adam », permet de mieux voir la pente de la colonne vertébrale et d'observer toute déformation de la colonne vertébrale [11].



Figure 1. 18 : Diagnostic médical par observation [25]

## 10.1 Examen radiographique

Rayons X Ces études fournissent des images de structures denses, telles que l'os. Votre médecin peut vous prescrire des radiographies sous différents angles pour déterminer s'il y a des changements dans les vertèbres ou toute autre anomalie osseuse.

Les rayons X permettront également de mesurer le degré de la courbe cyphotique. Une courbe supérieure à 50 degrés est considérée comme anormale.

Tests de fonction pulmonaire. Si la courbe est sévère, votre médecin peut prescrire des tests de la fonction pulmonaire. Ces tests aideront à déterminer si la respiration de votre enfant est restreinte en raison de la diminution de l'espace thoracique.

D'autres épreuves. Chez les patients atteints de cyphose congénitale, les courbes progressives peuvent entraîner des symptômes de compression de la moelle épinière, notamment des douleurs, des picotements, des engourdissements ou une faiblesse dans le bas du corps. Si votre enfant présente l'un de ces symptômes, votre médecin peut vous prescrire des tests neurologiques ou une imagerie par résonance magnétique (IRM) [11].

## **11. Conclusion**

En résumé, la cyphose et lordose sont des déformations de la colonne vertébrale qui peut survenir à n'importe quel âge (rarement à l'âge adulte). Nous avons vu que le dépistage joue un rôle central dans l'évolution de cette maladie, qu'il s'agisse du dépistage par des spécialistes, c'est-à-dire kinésithérapeutes, médecins, etc., ou par suivi lordose et la cyphose. En effet, si le dépistage est fait à un jeune âge, la lordose et la cyphose ne s'aggrave pas si le patient a subi une thérapie physique, le patient se souciera moins de cette déformation. Malheureusement, si la lordose et la cyphose ne sont pas détectée à temps est devenue une cyphose et lordose légère ou modérée, un traitement orthopédique avec des semelles orthopédiques ou des corsets sera nécessaire. Enfin, si la cyphose et la lordose est sévère, une intervention chirurgicale est nécessaire, mais pas obligatoire, c'est le patient qui prendra la décision.

Dans le chapitre suivant, nous allons présentons les méthodes de la segmentation des vertèbres et des intervertébraux.



## **Chapitre 2 : Différentes Architectures Des Réseaux De Neurones Profonds**



## **1. Introduction**

Les réseaux de neurones ont prouvé au fil des années leur efficacité dans de nombreuses tâches telles que la localisation, la classification, la détection et la segmentation d'objets. Dans ce chapitre, nous allons commencer par introduire le réseau de neurones convolutif et décrire les outils et les opérations de base utilisés pour construire une architecture d'un tel réseau. Ensuite, nous présenterons une revue de la littérature des réseaux de classification les plus populaires et expliquerons certains des composants les plus importants qui ont amélioré la précision de ces modèles au cours des dernières années. Nous terminerons par une revue littéraire des réseaux les plus connus utilisés pour les tâches de segmentation sémantique en mettant en évidence les clés de réussite de chaque modèle.

## **2. Réseaux de neurones convolutionnels**

Ces dernières années, l'apprentissage machine a permis d'obtenir des résultats plus proches ou meilleurs que les humains dans de nombreux domaines tels que la reconnaissance vocale [35][36][37], la reconnaissance faciale [38][46], la classification d'images [40][41], la détection d'objets [42], etc.

L'apprentissage automatique consiste à utiliser un ordinateur pour apprendre à gérer et à résoudre des problèmes sans programmation. Le processus est de construire un modèle basé sur des entrées connues, puis utiliser ce modèle pour prédire sur des nouvelles données.

L'idée est de permettre à la machine de créer un programme qui prend une entrée connue et de prédire une sortie intelligente similaire à une sortie connue d'une entrée différente.

Les réseaux de neurones artificiels sont des modèles d'apprentissage statistique, inspirés des réseaux neuronaux biologiques du système nerveux humain (figure 2.1). Ils sont utilisés dans l'apprentissage automatique et la reconnaissance de formes. Un neurone biologique a un ensemble de dendrites d'entrée qui reçoivent des signaux électriques. Lorsque le signal passe un seuil, le neurone est activé et le signal est transmis à l'axone connecté à d'autres neurones par des dendrites.

Le fonctionnement d'un seul perceptron est limité. Un simple perceptron ne peut classer que des données qui pourraient être séparées par un hyperplan. Le problème, dans la plupart des cas, est qu'il n'est pas possible de séparer linéairement

## Chapitre 2 : Architecture réseaux de neurones profonds

les données d'entrée. Même un simple XOR ne peut pas être adressé par un perceptron.




Figure 2. 1 : Neurone biologique et son modèle mathématique [45]

Dans les années 1980, le problème a été résolu avec l'introduction du perceptron multicouches.

Dans les réseaux de neurones artificiels, en tant que vrais neurones humains, les perceptrons sont reliés les uns aux autres et reproduisent un comportement similaire. Ces réseaux sont représentés comme des systèmes neuronaux interconnectés qui envoient des messages les uns aux autres.

Les modèles qu'ils reconnaissent sont numériques, contenus dans des vecteurs et des matrices, dans lesquels toutes les données du monde réel, comme les images, les sons, les textes ou les vidéos, doivent être traduites en données caractéristiques. Les connexions au sein du réseau peuvent être systématiquement ajustées en fonction des entrées et des sorties, ce qui les rend idéales pour l'apprentissage supervisé. Les réseaux de neurones sont utilisés pour regrouper et classer les données non étiquetées en fonction de similarités entre les nouvelles données et les échantillons déjà étudiés.

La combinaison des perceptrons permet d'approcher n'importe quelle fonction non linéaire en utilisant plus ou moins de couches et de neurones par couche. Cela permet de travailler sur des données plus complexes qui doivent être séparées par des hypersurfaces. Dans un réseau de neurones, les perceptrons sont organisés en couches. Il existe trois types de couches : couche d'entrée, couches cachées et couche de sortie. Les réseaux de neurones peuvent être classés en fonction de leur nombre de couches cachées et de leur connexion. Les réseaux neuronaux comportant plus de deux couches cachées peuvent être considérés comme un réseau neuronal profond.

## Chapitre 2 : Architecture réseaux de neurones profonds

L'avantage d'utiliser des réseaux neuronaux plus profonds est que des modèles plus complexes peuvent être reconnus. Ces réseaux nécessitent plus de données **pour éviter les surajustements** au cours d'apprentissage.

Les neurones lisent une entrée, la traitent et génèrent une sortie. Les neurones entre deux couches adjacentes sont entièrement connectés. Chaque connexion a un poids qui contrôle le signal entre les deux neurones. Chaque neurone artificiel calcule la somme des produits entre les poids et les entrées qui lui sont venues, puis ajoute un biais. Le résultat est ensuite passé à travers une fonction d'activation qui va ajouter de la non-linéarité (figure 2.1).

Un réseau de neurones est un système adaptatif, il peut changer sa structure interne en fonction de l'information qui lui est transmise en ajustant ses poids. Un ensemble de données appelé ensemble d'apprentissage doit être utilisé. Ces données sont formellement définies comme un ensemble de paires : entrées et cibles. L'objectif de l'apprentissage est d'optimiser les poids afin que le réseau neuronal puisse apprendre à mapper correctement les entrées inconnues aux sorties.

Si le réseau génère une bonne sortie, il n'est pas nécessaire d'ajuster les poids.

Cependant, si le réseau génère une mauvaise sortie, le système ajuste et modifie les poids pour améliorer les résultats ultérieurs.

Pour l'ensemble d'apprentissage, le résultat théorique est connu et l'optimisation consiste à **minimiser l'erreur de prédiction**. Cette erreur est la somme des carrés des différences entre les sorties calculées et les sorties attendues. Il est donc nécessaire d'optimiser numériquement la fonction d'erreur pour trouver la fonction qui donne la meilleure approximation de l'entrée par rapport à la cible. La rétropropagation est un tel algorithme qui effectue une minimisation d'erreur en utilisant la descente de gradient.

L'utilisation de réseaux de couches entièrement connectés pour la segmentation d'image n'est pas une bonne idée. La raison en est qu'une telle architecture de réseau traite les pixels de l'image et ne prend pas en compte la structure spatiale des images.

Pour surmonter ce problème, les couches de convolution ont été incluses dans les réseaux de neurones réguliers.

## Chapitre 2 : Architecture réseaux de neurones profonds

Ces couches considèrent le contexte et les informations spatiales des pixels voisins, ce qui conduit à apprendre plus d'informations à partir de l'entrée.

Les réseaux de neurones convolutionnels ont une architecture différente de celle des réseaux de neurones réguliers. Généralement, les réseaux de neurones convolutionnels sont composés de trois types principaux de couches :

Les couches convolutives, les couches de sous-échantillonnage et les couches entièrement connectées.

La configuration et le nombre de ces couches dans l'architecture du réseau dépendent du type et de la complexité du problème.

### **3. Couches de convolution**

Le but principal de la convolution est l'extraction d'informations à partir de l'image d'entrée.

La convolution est effectuée en faisant glisser une matrice de poids, appelée filtre, sur l'image d'entrée et en multipliant à chaque position les valeurs de filtre avec les valeurs de l'entrée.

Ce filtre est appliqué à chaque fois sur une zone spécifiée appelée champ réceptif.

Les résultats de la multiplication sont ensuite additionnés en un seul nombre.

La sortie de la convolution du filtre sur toute l'image est une matrice appelée la carte de caractéristiques (figure 2.2).

De nombreux filtres seront utilisés dans chaque couche de convolution, et chaque filtre vise à identifier un motif de base spécifique qui constitue les objets dans l'image tels que les formes et les bords. Les cartes de caractéristiques sont ensuite disposées les unes sur les autres pour former un volume de sortie en tant que sortie finale.

La profondeur de la sortie finale correspond



## Chapitre 2 : Architecture réseaux de neurones profonds

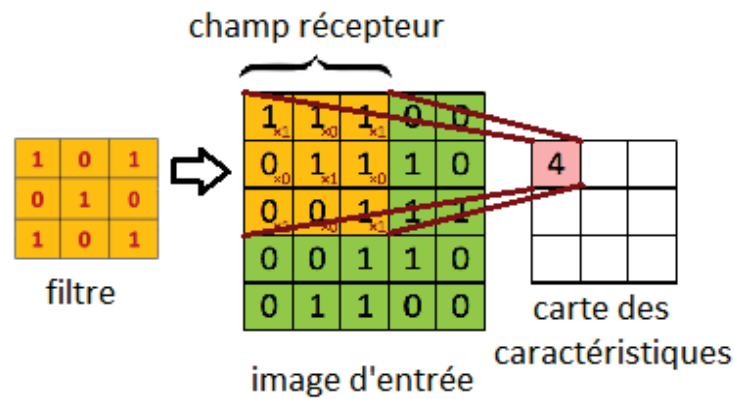


Figure 2. 2 : Convolution avec un filtre de taille 3x3 [47]

La région où le masque est appliqué et appelée champ réceptif.

Au nombre de filtres utilisés dans la couche de convolution. La taille spatiale de ces résultats dépend de la taille des filtres et de certains paramètres supplémentaires tels que le pas et le remplissage à zéro.

Le pas est le nombre de pixel par lesquels le filtre de convolution se déplace à chaque fois sur la matrice d'entrée. Un pas de 1 est le plus utilisé, ce qui signifie que le filtre glisse sur l'entrée d'un pixel à la fois.

Avec des valeurs de pas plus élevées, le filtre saute sur un grand nombre de pixels à la fois ce qui produit une sortie plus petite. Dans certains travaux, le concepteur de réseau convolutif préfère conserver la même taille de sortie que l'entrée. Dans ce cas, un processus connu sous le nom de remplissage avec zéro pourrait être utilisé. Cela nécessite seulement l'ajout de zéro pixel aux bordures de l'image d'entrée. Le mouvement du filtre avec un pas de 1 avec l'ajout d'un seul remplissage de zéro conservera la taille de l'entrée d'origine.

La taille spatiale de chaque carte de caractéristiques dépend de tous ces paramètres, elle peut être calculée comme suit.

$$S = \frac{E - F + 2 * Z}{P} + 1 \quad (2.1)$$

Où, S et E correspondent aux tailles d'entrée et de sortie, F est la taille du filtre, Z est le nombre de remplissage de zéro et P est la valeur de pas.

## Chapitre 2 : Architecture réseaux de neurones profonds

Comme les réseaux de neurones réguliers, la sortie de la convolution est passée à travers la fonction d'activation pour rendre la sortie non linéaire.

### 3.1 Fonction D'ACTIVATION




Figure 2. 3 : Convolution avec un filtre de taille 3x3 [47]

Pour PReLU,  $a_i$  est appris dans l'entraînement par propagation arrière et pour Leaky ReLU  $a_i$  est fixe.

La convolution est une opération linéaire. Le but de la fonction d'activation est d'introduire la non-linéarité. C'est une opération supplémentaire utilisée après chaque opération de convolution.

La fonction tangente hyperbolique et la fonction sigmoïde ont été largement utilisées dans L'apprentissage automatique et dans certaines implémentations de réseaux neuronaux de base. L'unité linéaire rectifiée (ReLU), introduit par Nair & Hinton [50], devient la non-linéarité la plus fréquemment utilisée dans les réseaux de neurones convolutionnels. Cette fonction met simplement les entrées négatives à zéro. Tous les éléments positifs l'information spatiale et la profondeur restent inchangés. Toutes les valeurs négatives deviennent nulles, ce qui réduit la capacité du modèle à s'entraîner ou à s'ajuster correctement aux données.

Le problème ici est que la sortie sera toujours nulle si l'entrée est négative aussi que le gradient. Cela peut essentiellement désactiver (tuer) les neurones et les empêcher d'apprendre. Pour surmonter ce problème, Maas et al ont proposé le Leaky ReLU qui est une variante de ReLU [48].

## Chapitre 2 : Architecture réseaux de neurones profonds

Cette fonction n'affecte aucune sortie nulle pour une entrée négative. Elle compresses les entrées négatives avec un facteur prédéfinie. Cela permet de conserver la partie négative dans les cartes de caractéristiques. He et al ont proposé l'unité linéaire paramétrique rectifiée (PReLU) qui généralise aussi le ReLU traditionnel [43].

La fonction d'activation générique est définie comme suit :

$$f(x_i) = \max(0, x_i) + a_i \min(0, x_i)$$

Dans la fonction PReLU, contrairement au fonction LReLU, le paramètre  $a_i$  est appris lors de l'apprentissage avec les autres paramètres du réseau neuronal par propagation arrière. Xu et al [51][46] ont examiné les performances de divers types de fonctions d'activation rectifiées telles que ReLU, Leaky ReLU et PReLU (figure 8.3). Basé sur des évaluations sur différentes tâches de classification d'image, ils ont prouvé que la fonction PReLU peut réduire l'erreur dans les étapes d'apprentissage et de test plus que le ReLU normal.

Après la convolution et la fonction de non-linéarité, la plupart des RNC ajoutent une couche de sous-échantillonnage (Pooling) entre les couches de convolution. Elle est utilisé en continu pour réduire la dimensionnalité et le nombre de paramètres. Cela raccourcit le calcul et le temps d'apprentissage dans le réseau et contrôle le sur-apprentissage.

### 3.2 Sous-échantillonnage



Figure 2. 4 : Différents types de Pooling 2x2 avec un pas de 2

Pour le pool maximum, la sortie est la valeur maximale dans chaque fenêtre de taille 2x2. Pour la mise en pool moyenne, la sortie est la moyenne des valeurs dans chaque fenêtré. Chaque couleur représente la fenêtre utilisée et sa sortie correspondante.

Le sous-échantillonnage, également appelé Pooling, réduit la taille des cartes d'activation en conservant les informations les plus importantes. Comme les couches convolutives, le Pooling consiste à faire glisser une fenêtre sur les cartes d'activation.

## Chapitre 2 : Architecture réseaux de neurones profonds

Il fonctionne indépendamment sur chaque tranche spatiale de l'entrée et redimensionne sa taille.

Il existe plusieurs types de sous-échantillonnage, les plus populaires sont le pool maximum et le pool moyen (figure 2.4).

Le pool maximum consiste à faire glisser une fenêtre sur la carte d'activation et à prendre à chaque fois le maximum de valeurs. Pour le pool moyen, la sortie à chaque fois est la moyenne des valeurs dans la fenêtre. La taille de la fenêtre et la foulée utilisée doivent être prises en compte.

Contrairement à l'opération de convolution, la mise en pool n'a pas de paramètres. Une nouvelle version de sous-échantillonnage, connue sous le nom de pool moyens globales, a été proposée par Lin et al [52]. L'objectif était d'éviter l'utilisation de couches traditionnelles entièrement connectées à la fin du réseau qui nécessitent beaucoup de temps en raison du grand nombre de paramètres qu'elles utilisent. L'idée était de générer une carte de caractéristiques pour chaque catégorie correspondante de la tâche de classification dans la dernière couche de convolution. Ensuite, au lieu d'utiliser les couches entièrement connectées, une moyenne de chaque carte de caractéristique est calculée puis passée directement par une couche SOFTMAX.

De manière similaire aux couches de regroupement moyennes, les couches de regroupement moyennes globales sont utilisées pour réduire les dimensions spatiales d'un volume tridimensionnel.

Ils effectuent un type de réduction de dimensionnalité plus extrême, où le volume d'entrée est réduit à des dimensions de taille de  $1 \times 1 \times n$  ( $n$  est le nombre des cartes de caractéristiques) en prenant simplement la moyenne de toutes les valeurs dans chaque carte.

### 3.3 Sur-échantillonnage

L'inverse exact du Pooling (sous-échantillonnage) n'est pas possible dans le réseau de neurones convolutif.

Le sur-échantillonnage, connu aussi par un Pooling, est un inverse approximatif du Pooling. Au cours de l'étape de sous-échantillonnage, les emplacements des pixels choisis à chaque application d'un Pooling sont enregistrés dans un ensemble de variables de commutateur.

## Chapitre 2 : Architecture réseaux de neurones profonds

Ces variables sont ensuite utilisées pour la nouvelle reconstruction des régions en gardant la même structure avant l'application de un Pooling. Par exemple, dans le Pooling maximale, les pixels qui ont été maximum contiennent à nouveau les nouveaux maximums.

Après les couches de convolution et de sous-échantillonnage, les cartes d'activation doivent être préparées en tant qu'entrée pour les couches de classification. Cependant, ces couches finales ne peuvent accepter que des données unidimensionnelles. Le volume des cartes d'activation doit donc d'abord être aplati en un vecteur. Ensuite, le vecteur est utilisé comme entrée pour les couches de classification.

### **3.4 Couches entièrement connectées**

Dans la plupart des architectures des RNC, le bloc convolutif du réseau est suivi par une ou plusieurs couches entièrement connectées. Ces couches prennent en entrée les cartes de caractéristiques aplaties et les transmettent à travers le réseau de neurones. Elles calculent le score de chaque classe à partir des entités extraites de haut niveau des couches de convolution.

La dernière couche entièrement connectée est utilisée comme couche de classification.

Elle contient un seul nœud pour chaque classe cible dans le modèle.

Dans Fonction d'activation de la dernière couche Il existe diverses fonctions d'activation qui pourraient être appliquées à la dernière couche entièrement connectée. Cette fonction diffère d'une tâche à l'autre et elle est liée au résultat de sortie souhaité. La fonction d'activation appropriée pour la tâche de classification des pixels multi-classes est la fonction SOFTMAX. Cette fonction est la plus répandue et la plus utilisée pour les tâches de segmentation d'images. Elle normalise les valeurs réelles de sortie de la dernière couche entièrement connectée en des probabilités des classes cibles, où chaque valeur est comprise entre 0 et 1 et la somme de toutes les valeurs est 1.

### **4. Qu'est-ce que l'augmentation des DONNÉES ?**

Dans les deux réseaux de neurones convolutives précédents, nous avons créé des classificateurs simples en utilisant des images minuscules (28\*28 et 32\*32) pour créer des classificateurs d'images assez décents.

## Chapitre 2 : Architecture réseaux de neurones profonds

Cependant, dans les deux ensembles de données, nous avons des milliers d'échantillons d'images par catégorie.

Dans l'apprentissage profond, plus nous avons de données/exemples d'entraînement, plus notre modèle sera performant sur des données non vues (données de test).

Cependant. Que se passe-t-il si nous avons moins de 1000 exemples par classe d'image ? ,Voyons ce qui se passe...

### 4.1 Avantages de l'augmentation des données

Prendre un petit ensemble de données et le rendre beaucoup plus grand.

Nécessite beaucoup moins d'efforts pour créer l'ensemble de données.

L'ajout de variations telles que des rotations, des décalages, des zooms, etc. rend notre classificateur beaucoup plus invariant aux changements dans nos images, ce qui le rend beaucoup plus robuste.

Réduit le surajustement en raison de la variété accrue de l'ensemble de données de formation.

### 4.2 Types d'augmentation des données

Dans la pratique, j'ai constaté que ce sont les éléments suivants qui apportent le plus de bénéfices :

Rotations.

Décalages horizontaux et verticaux.

Cisaillement.

Le zoom.

Le cisaillement :




Figure 2. 5 : Objet avant et après n cisaillement [47]

### 5. Architectures de classification

Il existe plusieurs architectures dans le domaine des réseaux convolutifs. Les premières applications réussies de ces réseaux ont été développées par Yann LeCun dans les années 1990.

#### 5.1 LE-NET

L'architecture la plus connue était LE-NET-5 (LeCun et al [52]) . Celle-ci a été conçue pour la reconnaissance des caractères manuscrits et imprimés à la machine. Elle a été entraînée et testée sur la fameuse base de données des chiffres manuscrits MNIST 1 pour classer l'entrée dans l'une des dix classes représentant les chiffres 0 à 9. LE-NET-5 a été appliquée par plusieurs banques pour reconnaître les numéros manuscrits sur des chèques numérisés en images de 32x32 pixels.

La conception du LE-NET-5 contient les éléments de base des réseaux de neurones convolutifs utilisés dans les modèles les plus récents. L'architecture LE-NET-5 est composée de 7 couches au total. Trois couches convolutives, deux couches de sous-échantillonnage suivies d'un ensemble de couches entièrement connectées, et finie d'une couche sortie qui génère 10 sorties représentant les 10 chiffres de 0 à 9.

Dans les couches de sous-échantillonnage, les pixels voisins dans une fenêtre de taille 4x4 sont additionnés, multipliés par un coefficient entraîné, ajoutés à un biais entraîné et transmis par la fonction sigmoïde pour la non-linéarité.

Le suréchantillonnage réduit le nombre de paramètres et de calculs dans le réseau. Il réduit aussi la dimension de chaque carte tout en conservant les informations les plus importantes.

Les limites du matériel informatique et la capacité de la mémoire pour l'apprentissage en réseau ont rendu difficile la mise en œuvre de tels algorithmes. Par conséquent, les réseaux de neurones ont été mis à l'écart par la recherche depuis 1998 jusqu'au 2010.

Au cours des dernières années, plus de données sont devenues disponibles en raison de l'augmentation du nombre de dispositifs d'image et de l'explosion des données sur Internet. La puissance des processeurs graphiques (GPU) a augmenté également, ce qui a encouragé à reprendre les recherches sur les réseaux de neurones.

# Chapitre 2 : Architecture réseaux de neurones profonds

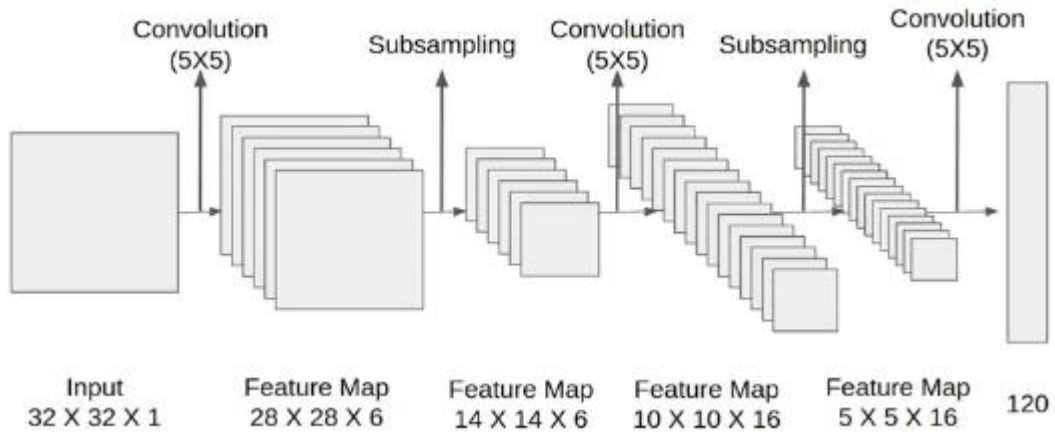


Figure 2. 6 : Architecture LE-NET 5 [53]

En 2010, Dan Claudiu Ciresan et Jurgen Schmidhuber ont publié l'une des premières implémentations de réseaux de neurones utilisant un GPU (Ciresan et al [54]). Ils ont obtenu un taux d'erreur de 0,35% sur la base de données MNIST. Ils ont prouvé dans leur étude que l'utilisation de nombreuses couches cachées, de nombreux neurones par couche, de nombreuses images d'apprentissage et des GPU a accéléré considérablement l'apprentissage et a mené à de meilleurs résultats.

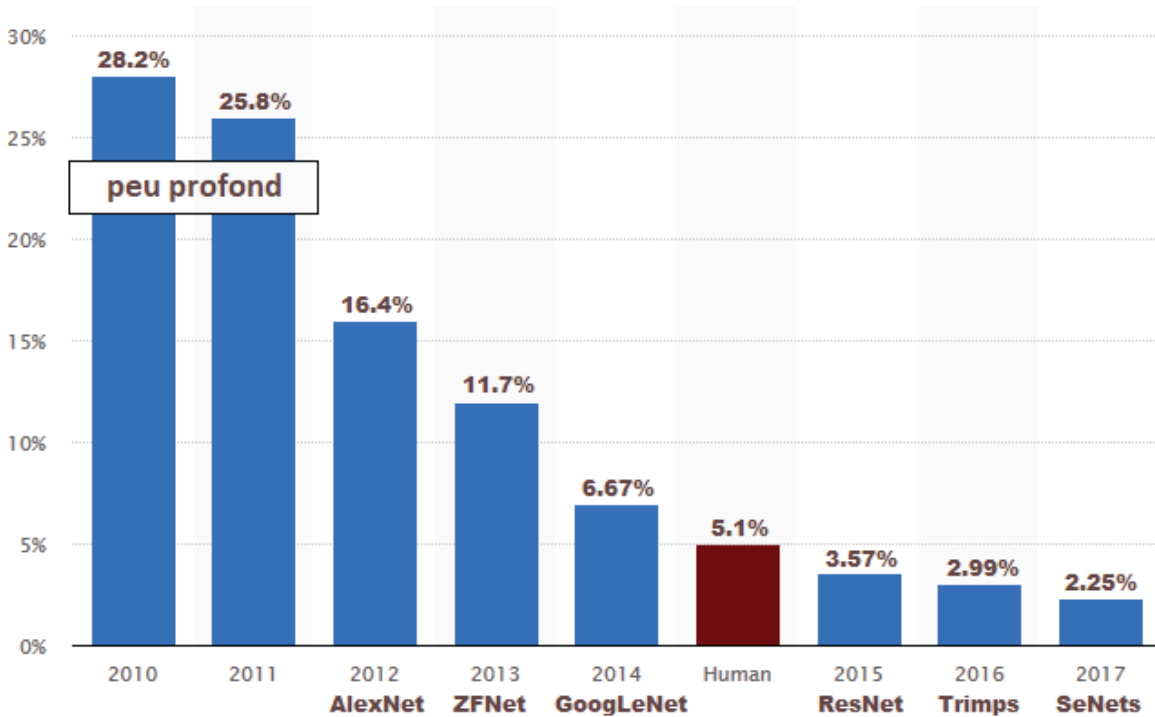


Figure 2. 7 : La progression de la performance de classement (erreur top-5%) des Plus performantes de la compétition ILSVRC au cours des dernières années [47]



### 5.2 ALEX-NET

En 2012, un modèle de réseau neuronal convolutionnel, connu sous le nom Alex-Net (Krizhevsky et al [40]), a fait une percée dans la compétition ILSVRC 2. Il a nettement surpassé les méthodes traditionnelles existantes et a remporté l'ILSVRC-2012 avec une erreur top-5 de 16,4% contre 26,2% atteint par le deuxième meilleur concurrent. C'était la première fois qu'une méthode d'apprentissage profond fut utilisée pour la classification d'images à grande échelle.

Alex-Net a une architecture similaire à LE-NET mais plus profonde, avec plus de filtres par couche.

Il se compose de cinq couches convolutives suivies de deux couches entièrement connectées et d'une couche SOFTMAX pour la classification. Contrairement à LE-NET, une opération de non-linéarité (ReLU) est utilisée après chaque convolution. Cette fonction est plus rapide que la fonction sigmoïde traditionnelle. À chaque étape d'apprentissage, la moitié des nœuds individuels de chaque couche entièrement connectée est retirée du réseau.

Ce qui améliore la capacité du réseau à généraliser et à éviter le surajustement des données d'apprentissage.

Depuis lors, une série de modèles de réseaux de neurones convolutionnels ont été proposés avec des architectures plus profondes et plus sophistiquées qui ont fait progresser l'état de l'art régulièrement sur la compétition ILSVRC comme le montre la figure 2.7.

En 2013, (Zeiler & Fergus [55]) ont remporté la compétition ILSVRC-2013 avec une architecture connue sous le nom ZF-Net.

Leur modèle a été une amélioration de l'architecture Alex-Net.

Il a été conçu en ajustant le réseau en réduisant la taille du filtre de la première couche de (11×11) à (7×7), ainsi que le pas de convolution de 4 à 2. Cette amélioration conserve plus d'informations sur les pixels et réduit le nombre de paramètres du réseau. Les auteurs de ZF-Net ont aussi introduit une nouvelle technique de visualisation des cartes de caractéristiques utilisant ce qu'on appelle la déconvolution. Cette opération fait l'opposé d'une couche convolutive permettant de visualiser les cartes caractéristiques dans le domaine des pixels et d'examiner

# Chapitre 2 : Architecture réseaux de neurones profonds

différentes cartes d'activation et leurs relations avec l'espace d'entrée.




Figure 2. 8 : Diagramme de l'architecture ALEX-NET [76]

## 5.3 VGG-NET

En 2014, (Simonyan & Zisserman [58]) (deuxième meilleur taux d'erreur top-5 à la compétition ILSVRC-2014) ont introduit un nouveau modèle appelé VGG-Net. Ce réseau de 19 couches a été une amélioration du réseau Alex-Net. Il se compose de cinq blocs principaux d'opérations de convolution connectés via des couches de pool maximum suivies par trois couches entièrement connectées. Chaque bloc de convolution contient une série de couches de convolution par des filtres de taille 3x3. L'utilisation de filtres de petites tailles permet d'extraire des caractéristiques plus complexes. Cette étude a prouvé d'une part que l'utilisation de la convolution avec des filtres 3x3 en séquence peut émuler l'effet d'un filtre plus grand et d'autre part que l'utilisation de plusieurs couches non linéaires avec des filtres de petite taille permet au réseau d'apprendre des fonctionnalités plus complexes à moindre coût.




Figure 2. 9 : Architecture VGG [59]

La révolution des réseaux de neurones convolutifs a eu lieu en décembre 2015. RES-Net (He et al. [47]), un réseau de 152 couches, a remporté la compétition ILSVRC-2015 avec un incroyable erreur top-5 de 3,57%. Ce résultat a dépassé la performance humaine (erreur top- 5 de 5,1%) sur l'ensemble de données Image-Net. Dans RES-Net, les couches de convolutions sont divisées en blocs résiduels. La

## Chapitre 2 : Architecture réseaux de neurones profonds

première couche dans cette architecture est une couche de convolution avec un filtre de taille 7×7 suivie d'une couche de pool maximum, de blocs résiduels, d'une couche de pool moyenne et d'une couche de classification. Le bloc résiduel est composé de trois couches de convolution avec des filtres de tailles 1×1 et 3×3. Une connexion résiduelle dans chaque bloc est utilisée pour fusionner par sommation la sortie transmise par les deux couches de convolution avec l'entrée original du bloc.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 <b>LRN</b>	conv3-64 <b>conv3-64</b>	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 <b>conv3-128</b>	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 <b>conv1-256</b>	conv3-256 conv3-256 <b>conv3-256</b>	conv3-256 conv3-256 conv3-256 <b>conv3-256</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Figure 2. 10 : Table de configuration VGG NET [20]

### 5.4 RES-NET

En 2016, l'équipe Soushen de l'institut de recherche Trimps de Chine ont proposé un réseau assemblant 5 versions différentes d'Inception est de RES-Net. Ce réseau a remporté la première place pour la classification des objets dans la compétition ILSVRC-2016 avec une erreur top-5 de 2,99%.

# Chapitre 2 : Architecture réseaux de neurones profonds

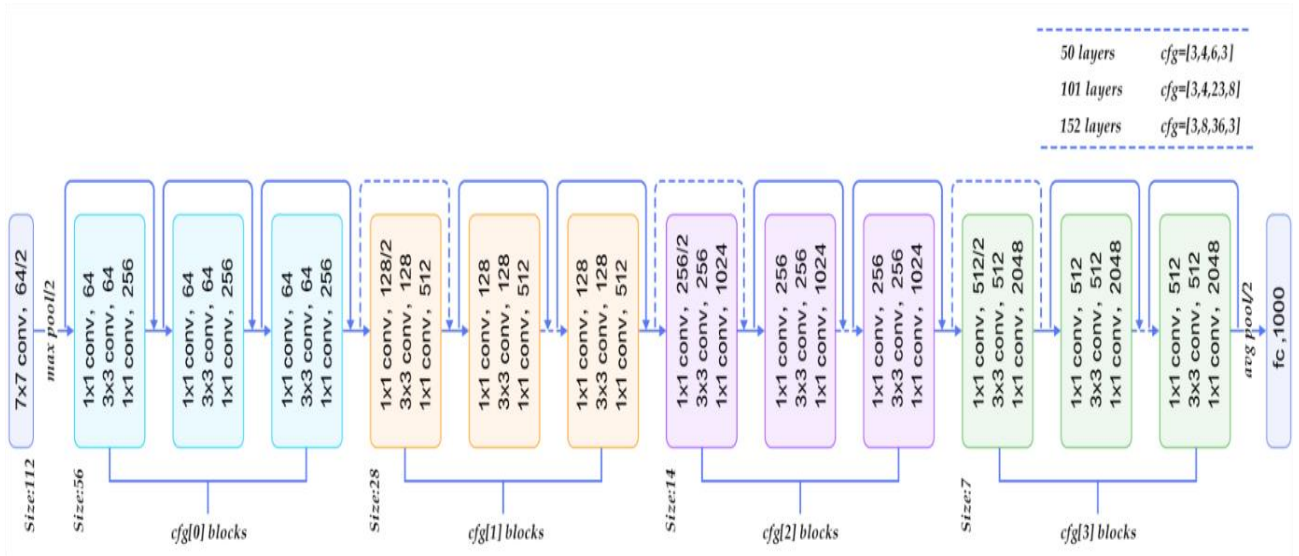


Figure 2. 11 : Architecture RES-NET [59]

La plupart des nouveaux modèles sont des versions améliorées par rapport aux modèles novateurs précédents ou un assemblage de réseaux existants. Après avoir obtenu des résultats supérieurs aux performances humaines avec des taux d'erreur inférieurs à 3% sur la base de données Image-Net, les efforts de la recherche se sont plus focalisés à améliorer le coût de calcul et la minimisation du nombre de paramètres utilisés dans le modèle.




Figure 2. 12 : Architecture RES-NET [19]

### **6. Architectures de segmentation**

La sortie prévue dans les réseaux de neurones de classification est une étiquette de classe unique. Cependant, dans de nombreuses tâches visuelles, en particulier dans le traitement d'images médicales, le résultat souhaité doit inclure une segmentation de certaines structures ou en d'autres termes, attribuer une étiquette de classe pour chaque pixel de l'image d'entrée.

Le succès des modèles d'apprentissage pour la classification a incité les chercheurs à explorer la capacité de tels exploits pour résoudre les problèmes d'étiquetage au niveau des pixels.

Cet effort a donné naissance à de nouvelles techniques de segmentation telle que la segmentation sémantique.

À notre connaissance, la première méthode d'apprentissage profond utilisée pour la segmentation sémantique était la classification par patch. Inspiré par le succès des réseaux de neurones de classification précédents, cette approche classe séparément chaque pixel en utilisant un patch d'image centré sur le pixel d'intérêt.

Ning et al [62] ont proposé un réseau de neurones convolutif permettant d'étiqueter les pixels sur des séquences d'images microscopiques de petits groupes de cellules. Leur réseau est composé de 3 couches de convolution avec des filtres de tailles (7×7, 6×6 et 6×6).

Les deux premières couches de convolution sont chacune suivie d'une couche de sous-échantillonnage.

Contrairement à LE-NET-5, le sous-échantillonnage utilisé dans leur réseau calcule la moyenne dans un voisinage de (2×2). Cette moyenne est ensuite ajoutée à un biais entraîné, puis multipliée par un coefficient entraîné.

Le résultat est enfin transmis par la fonction tanh, L'étiquette prédite pour chaque pixel est obtenue en appliquant les opérations de convolution et de sous-échantillonnage à une fenêtre de taille (40×40) centrée sur le pixel d'intérêt de l'image d'entrée.

La couche finale comprend cinq unités, chacune représente une classe.

En utilisant la même stratégie de classification par pixel, Ciresan et al [63] ont proposé un réseau de neurones convolutif pour la segmentation des membranes de neurones biologiques dans des images microscopiques électroniques.

## Chapitre 2 : Architecture réseaux de neurones profonds

Leur apport majeur était l'utilisation des couches de pool maximum au lieu du sous-échantillonnage après chaque couche de convolution.

La dernière couche est une couche entièrement connectée. Elle contient un certain nombre de neurones représentant chacune une catégorie prédéfinie (deux dans leur cas). L'application de la fonction SOFTMAX leur permet à la fin de calculer la probabilité d'appartenance de chaque pixel à une des dites catégories.

L'approche de la classification par patch fonctionne bien dans de nombreuses situations, mais présente deux inconvénients majeurs.

Tout d'abord, le réseau s'exécute séparément pour chaque patch, ce qui le ralentit généralement. Deuxièmement, l'utilisation de patch de grande taille nécessite l'utilisation d'un plus grand nombre de couches de pool maximum, ce qui réduit la précision de localisation, tandis que l'utilisation d'un patch de petite taille empêche le réseau d'apprendre les propriétés du contexte global. Puisque la sortie du réseau de classificateur de pixel par patch est une étiquette pour un seul pixel, la taille de l'image d'entrée doit être fixée.

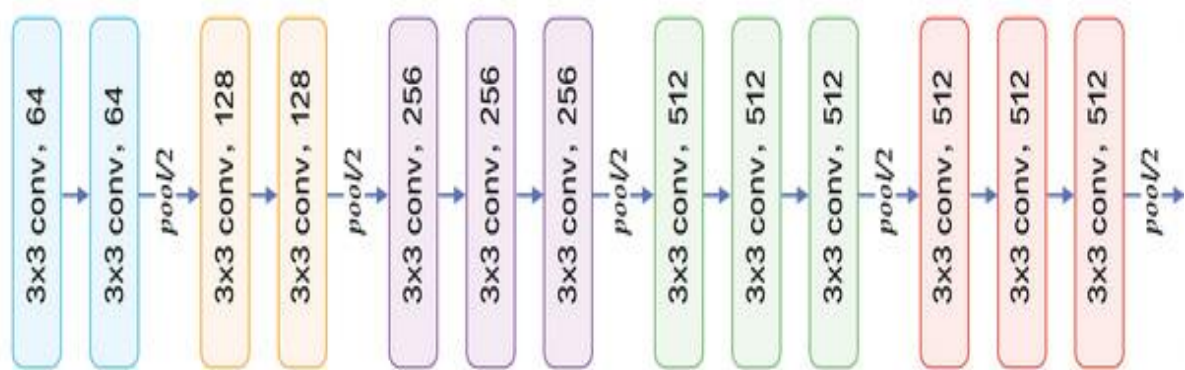


Figure 2. 13 : Partie convolutive (encodeur) de l'architecture VGG-16 [47]

Des filtres de taille 3x3 sont utilisés pour toutes les couches de convolution.

Le nombre dans les rectangles correspond au nombre de filtres utilisés pour chaque couche. Les opérations de pool maximum sont utilisées entre les blocs de convolution pour réduire la dimension spatiale des cartes de caractéristiques.

Pour dépasser ces limites, Long et al [64] ont adapté certains des réseaux de classification les plus réputés (Alex-Net, VGG-Net) pour créer un réseau de neurones entièrement convolutif.



## Chapitre 2 : Architecture réseaux de neurones profonds

Dans leur étude, ils ont mis au point les trois réseaux de classification différents.

Les meilleurs résultats ont été obtenus avec une architecture basée sur le réseau VGG-16 qui est une version de VGG-Net à 16 couches (13 couches de convolutions et 3 couches entièrement connectées).

Leur idée était de conserver les couches de convolutions (figure 2.13) et de remplacer les couches entièrement connectées par des couches de convolutions avec des filtres de taille  $1 \times 1$ .

L'utilisation des couches entièrement convolutives permet de traiter des images de taille arbitraire. Du fait que les couches de pool maximum sont utilisées, la taille de sortie de la couche finale est réduite. Pour redimensionner la carte de sortie à la taille d'origine de l'entrée, ils ont utilisé des couches de sur-échantillonnage avec une déconvolution initialisée de manière linéaire. Utiliser uniquement la sortie sur-échantillonnée de la dernière couche n'était pas suffisant pour obtenir une bonne segmentation. Pour cette raison, ils ont fusionné la sortie de la couche finale avec les cartes de caractéristiques de couches peu profondes de différents niveaux. Cette combinaison permet d'obtenir des prédictions locales tout en respectant les structures globales, ce qui permet au réseau d'obtenir des segmentations plus précises.

Au meilleur de notre connaissance, l'utilisation des couches de sur-échantillonnage a été d'abord présentée par Huang et al [65] dans une architecture d'apprentissage non supervisée.

Un réseau de déconvolution a également été introduit par Zeiler et al [66] pour reconstruire les images d'entrée à partir de sa représentation fonctionnelle. Zeiler & Fergus [55] ont utilisé des couches de déconvolution dans leur travail pour comprendre le comportement des réseaux de neurones convolutionnels en visualisant des cartes de caractéristiques de différents niveaux.

Afin de mieux récupérer les pertes d'informations causées par les couches de sous échantillonnage, les chercheurs ont poussé l'idée proposée dans le travail de Long et al. (2015) un peu plus loin en élargissant la partie de sur-échantillonnage des cartes de caractéristiques et en ajoutant davantage de liaisons de sauts entre les couches de différents niveaux.

Ce type d'architecture est connu sous le nom de réseau encodeur-décodeur.

### 6.1 Architecture encodeur-décodeur

La première partie de l'architecture du réseau est appelée encodeur. Elle est similaire à la partie de convolution d'un réseau de classification. Des blocs de couches de convolution suivis chacun d'une couche de sous-échantillonnage sont utilisés pour convertir l'image d'entrée en cartes de caractéristiques.

La deuxième partie est le décodeur qui est une version miroir de l'encodeur. Elle comprend plusieurs ensembles de couches de déconvolution et de sur-échantillonnage pour récupérer les informations spatiales à partir de la sortie de l'encodeur. La dernière couche du décodeur est une couche de classification SOFTMAX qui produit une segmentation finale de la même taille que l'image d'entrée.

Il existe généralement des connexions d'encodeur vers décodeur pour aider le décodeur à réduire la perte d'informations et à mieux récupérer les détails de l'objet d'intérêt. De nombreuses architectures ont été développées sur la base du concept encodeur-décodeur (Badrinarayanan et al [67] , Noh et al [68]. Ronneberger et al [69] . Badrinarayanan et al [70]).

Ce qui différencie une architecture des autres est la façon dont elle relie les différents niveaux de l'encodeur avec leurs parties inversées dans le décodeur.

Badrinarayanan et al [70] ont développé une architecture de forme encodeur-décodeur, connue sous le nom SEG-NET, pour la segmentation multi-classes des pixels. La partie encodeur de SEG-NET est similaire aux 13 couches convolutives du réseau VGG-16 (figure 2.13).

Elle est composée de cinq blocs. Chaque bloc est constitué de couches de convolution 2D, de normalisation par lots et d'une activation d'unité rectifiée linéaire (ReLU).

La dernière couche du bloc est une couche de pool maximum qui vise à réduire la dimension spatiale des cartes de caractéristiques.

Pour récupérer la haute résolution des cartes de caractéristiques, SEG-NET a utilisé un processus inverse de la partie encodeur en tant que décodeur avec le même nombre de blocs.

Chaque bloc est constitué d'une couche de sur-échantillonnage suivie par des couches convolutives entraînées, normalisation par lots et d'une activation (ReLU).



## Chapitre 2 : Architecture réseaux de neurones profonds

Un élément clé de l'architecture SEG-NET est l'utilisation des emplacements restaurés de pool maximum pour effectuer un sur-échantillonnage dans la partie décodeur. Ce processus permet de conserver des détails haute fréquence dans les images segmentées avec un faible coût de consommation de mémoire et un nombre réduit de paramètres d'apprentissage dans la phase de décodeur.

### 6.2 Architecture U-NET

Une autre architecture de type encodeur-décodeur, connue sous le nom U-NET, a été proposée par Ronneberger et al [69]. U-NET a montré d'excellentes performances en segmentant différentes cibles dans différentes modalités d'images médicales.

L'architecture est composée de 23 couches de convolution au total. Elle consiste en un chemin de contraction (encodeur) et un chemin d'expansion (décodeur). Comme SEG-NET, la partie encodeur est composée de blocs de convolution répétés. Chaque bloc est constitué de deux couches de convolutions avec des filtres de taille (3x3), chacune suivie d'une activation (ReLU) et d'une opération de pool maximum de (2x2).

Le nombre de cartes de caractéristiques est doublé après chaque sous échantillonnage.

La partie d'expansion de U-Net est une version inversée de la partie contraction.

Le nombre de cartes de caractéristiques est réduit de moitié après chaque bloc. Pour connecter la partie codeur à la partie décodeur correspondante, une copie des cartes de caractéristiques est concaténée avec les cartes correspondantes de la partie décodeur. La dernière couche utilise une convolution avec des filtres de tailles (1x1) pour fournir des cartes de classification de même nombre que les classes souhaitées. La taille de sortie est inférieure à la taille d'entrée en raison de l'utilisation de la convolution sans l'ajout de pixels autour de l'image. Pour obtenir la même taille que l'entrée, l'image entière est prédite partie par partie à l'aide d'une stratégie de mosaïque de chevauchement.

Le nombre d'échantillons annotés dans le domaine médical est généralement limité car cela devrait être fait par des experts. D'autre part, les réseaux d'apprentissage dans un tel domaine nécessitent un grand nombre d'échantillons.

Pour surmonter cette limite, Ronneberger et al [69] ont augmenté la taille de l'ensemble d'apprentissage en utilisant des transformations aléatoires sur les images

## Chapitre 2 : Architecture réseaux de neurones profonds

d'entrée telles que les inversions, les distorsions, les rotations et en particulier les déformations élastiques.

Cependant, les architectures encodeur-décodeur n'étaient pas la seule solution pour réduire les inconvénients liés à l'utilisation de couches de sous-échantillonnage. Yu & Koltun [71] ont développé un nouveau modèle permettant d'obtenir le contexte global de l'image sans réduire la taille de l'image en utilisant une nouvelle forme de convolution appelée convolution dilatée (ou convolution à trous). La convolution dilatée est utilisée pour maintenir la résolution spatiale des cartes de caractéristiques d'une couche à l'autre en augmentant simplement le champ de vision du filtre.




Figure 2. 14 : Architecture U-net [47]

Chaque rectangle bleu correspond à une carte de caractéristiques multicanaux. Le nombre de canaux est indiqué en haut du rectangle. La taille spatiale est indiquée sur le bord inférieur gauche du rectangle. Les rectangles blancs représentent les cartes de caractéristiques copiées. Les flèches indiquent les différentes opérations. Figure reproduite et adaptée avec l'autorisation de (Ronneberger *et al.* (2015)).

Ce processus est effectué en insérant des zéros entre les pixels du filtre de convolution. Yu & Koltun (2015) ont proposé un réseau basé sur le modèle VGG-16 qui consiste à utiliser une série de couches de convolution dilatées de différents facteurs.

## Chapitre 2 : Architecture réseaux de neurones profonds

Ces facteurs de dilatation augmentent suivant une fonction exponentielle allant des couches peu profondes aux couches plus profondes.

Chen et al. (2014) ont choisi de traiter les inconvénients des opérations de sous-échantillonnage comme une étape de post-traitement.

Ils ont utilisé un réseau basé sur le modèle VGG-16 et ont proposé d'affiner la segmentation de la sortie pour récupérer les détails les plus fins.

Leur idée était de combiner la carte des scores de la dernière couche de réseau avec un modèle de champ aléatoire conditionnel (CRF) entièrement connecté qui a été développé par (Krähenbühl & Koltun [72]).

Le CRF utilise une fonction d'énergie qui combine les informations d'interactions entre les paires de pixels, leurs positions et leurs intensités, avec la probabilité d'appartenance prédite par le réseau pour chaque pixel. Cette étape de post-traitement permet de récupérer les structures détaillées perdues lors de la segmentation finale.

Chen et al [73] ont proposé une nouvelle version de leur approche précédente. Plus que le VGG-16, ils ont construit une seconde architecture basée sur le réseau RES-NET-101 (RES-Net à 101 couches).

Comme dans la première version, ils ont utilisé la convolution dilatée et le CRF comme une étape de post-traitement. L'amélioration consistait à utiliser un traitement à plusieurs échelles en transmettant les cartes de caractéristiques par une mise en pool à trous en pyramide spatiale (ASPP).

Cette technique utilise des filtres dilatés pour augmenter le champ de vision lors de la convolution dans une forme de pyramide spatiale afin de capturer des cartes de caractéristiques à plusieurs échelles.

ASPP utilise une série de convolutions dilatées, de manière parallèle, avec des taux de dilatation différents. Les cartes de caractéristiques des différentes branches parallèles sont ensuite interpolées de manière bilinéaire à la résolution de l'image d'origine. La sortie est finalement générée en prenant la réponse maximale à chaque position parmi les différentes sorties de chaque branche.

### **7. Conclusion**

Dans ce chapitre, nous avons d'abord présenté les outils de base permettant de concevoir une architecture de réseau de neurones convolutif. Nous avons ensuite présenté une analyse des architectures les plus populaires utilisées pour la classification d'images telles que Alex-Net, VGG-Net et RES-Net et on fait la comparaison entre les architectures.

Nous avons discuté les améliorations et les idées clés de chaque réseau en fonction de leur performance de la compétition annuelle Image-Net. Enfin, nous avons passé en revue certains des réseaux populaires utilisés pour les tâches de segmentation sémantique telles que les réseaux encodeur-décodeur et les architectures basées sur la convolution dilatée.

Nous avons aussi expliqué en détail les différentes opérations développées par chaque approche pour obtenir une segmentation finale de la même taille que l'entrée initiale.

Et dans notre travail on a bien choisi l'architecture U-NET grâce à la limitation des performances de test et de l'entraînement (carte graphique de mauvaise performance) et aussi parce que le U-NET traite le concept de L'étiquetage des données surtout dans le domaine de la diagnostique médicale, est idéale pour préserver la taille initiale.



## **Chapitre 3 : Méthodes De Segmentation Des Vertèbres Et Des Disques Intervertébraux**



# Chapitre 3 : Méthodes de segmentation des vertèbres et des disques intervertébraux

## 1. Introduction

Après avoir compris les principaux outils permettant de concevoir une architecture de réseau neuronal, nous proposons dans ce chapitre un réseau neuronal convolutif qui est U-NET pour segmenter la colonne vertébrale lombaire. Comme nous l'avons expliqué au chapitre précédent, le principal problème que tous les réseaux proposés visent à résoudre est la perte de certaines informations structurales lors de la convolution et des opérations de sous-échantillonnage, ce qui produit une solution qui n'est pas optimale de façon globale. Pour résoudre ce problème, nous allons utiliser la ligne de partage des eaux et détection de contours pour affiner les prédictions finales. Nous allons utiliser dans notre étude une base de données qui contient les images IRM et uniquement les annotations des vertèbres.

## 2. Architecture de réseau proposée

La méthode de segmentation proposée est basée sur une architecture de réseau de neurones entièrement convolutif à deux dimensions. Cette architecture est composée de 24 couches au total avec la disposition suivante : 18 couches de convolution. Pour les deux premières couches, nous avons utilisé 32 filtres de taille (3×3) dans chaque couche. Dans les deux couches de convolution suivantes, nous avons utilisé 64 filtres de taille (3×3) dans chaque couche. Ensuite pour les deux couches de convolution suivantes, nous avons utilisé 128 noyaux de taille (3×3) sont utilisés dans chaque couche 128 noyaux de taille (3×3) sont utilisés dans chaque couche. Dans les deux couches de convolution suivantes, nous avons utilisé 256 filtres de taille (3×3) dans chaque couche.

Après en passe à la phase de décodage la première couche est la déconvolution plus deux couches de convolution, nous avons utilisé 128 filtres de taille (3×3) dans chaque couche. Ensuite on a une couche déconvolution plus deux couches de convolution, nous avons utilisé 64 noyaux de taille (3×3) sont utilisés dans chaque couche. Et enfin, on a une couche de déconvolution plus deux couches de convolution, nous avons utilisé 32 noyaux de taille (3×3) sont utilisés dans chaque couche.

Après chaque convolution on a utilisé la fonction ReLU pour désactiver tous les nœuds qui possède des valeurs négative, Cela rend très efficace sur le plan du calcul

car peu de neurones sont activés à la fois, et à la fin de chaque phase on a appliqué un max-pooling ça nous a aidé à extraire des caractéristiques nettes et lisses. Cela permet également de réduire la variance et les calculs. Le max-pooling permet d'extraire des caractéristiques de bas niveau comme les bords, les points, etc.

Model: "UNET-L4-F32"

Layer (type)	Output Shape	Param #	Connected to
input_5 (InputLayer)	[(None, 320, 320, 1)]	0	
conv2d_44 (Conv2D)	(None, 320, 320, 32)	320	input_5[0][0]
conv2d_45 (Conv2D)	(None, 320, 320, 32)	9248	conv2d_44[0][0]
max_pooling2d_8 (MaxPooling2D)	(None, 160, 160, 32)	0	conv2d_45[0][0]
conv2d_46 (Conv2D)	(None, 160, 160, 64)	18496	max_pooling2d_8[0][0]
conv2d_47 (Conv2D)	(None, 160, 160, 64)	36928	conv2d_46[0][0]
max_pooling2d_9 (MaxPooling2D)	(None, 80, 80, 64)	0	conv2d_47[0][0]
conv2d_48 (Conv2D)	(None, 80, 80, 128)	73856	max_pooling2d_9[0][0]
conv2d_49 (Conv2D)	(None, 80, 80, 128)	147584	conv2d_48[0][0]
max_pooling2d_10 (MaxPooling2D)	(None, 40, 40, 128)	0	conv2d_49[0][0]
conv2d_50 (Conv2D)	(None, 40, 40, 256)	295168	max_pooling2d_10[0][0]
conv2d_51 (Conv2D)	(None, 40, 40, 256)	590080	conv2d_50[0][0]
conv2d_transpose_8 (Conv2DTrans)	(None, 80, 80, 128)	295040	conv2d_51[0][0]
concatenate_8 (Concatenate)	(None, 80, 80, 256)	0	conv2d_transpose_8[0][0] conv2d_49[0][0]
conv2d_52 (Conv2D)	(None, 80, 80, 128)	295040	concatenate_8[0][0]
conv2d_53 (Conv2D)	(None, 80, 80, 128)	147584	conv2d_52[0][0]
conv2d_transpose_9 (Conv2DTrans)	(None, 160, 160, 64)	73792	conv2d_53[0][0]



conv2d_54 (Conv2D)	(None, 160, 160, 64)	73792	concatenate_9[0][0]
conv2d_55 (Conv2D)	(None, 160, 160, 64)	36928	conv2d_54[0][0]
conv2d_transpose_10 (Conv2DTran	(None, 320, 320, 32)	18464	conv2d_55[0][0]
concatenate_10 (Concatenate)	(None, 320, 320, 64)	0	conv2d_transpose_10[0][0] conv2d_45[0][0]
conv2d_56 (Conv2D)	(None, 320, 320, 32)	18464	concatenate_10[0][0]
conv2d_57 (Conv2D)	(None, 320, 320, 32)	9248	conv2d_56[0][0]
conv2d_58 (Conv2D)	(None, 320, 320, 1)	33	conv2d_57[0][0]
=====			
Total params: 2,140,065			
Trainable params: 2,140,065			
Non-trainable params: 0			

Figure 3. 1 : Les couches du modèle U-NET

## 3. Réglage des hyperparamètres

### 3.1 Nombre d'époques

Le nombre d'époques correspond au nombre de fois où l'ensemble de données d'apprentissage complet passe en avant et en arrière dans le réseau neuronal. Nous avons formé notre réseau en 5 époques, chacune composée de 20 sous-époques.

### 3.2 Taille du lot d'images d'apprentissage

Dans l'apprentissage automatique, les données sont toujours trop volumineuses et nécessitent trop de mémoire si nous transmettons toutes les données dans le réseau en même temps. Pour résoudre ce problème, les données sont divisées en lots plus petits et transférées dans le réseau lot par lot. Les poids du réseau de neurones sont mis à jour à la fin de chaque étape pour les adapter aux échantillons utilisés.

À chaque sous-époque, un total de 207 échantillons sont sélectionnés au hasard de l'ensemble d'images d'apprentissage. Ils sont traités dans le réseau avec des lots de taille 2

### 3.3 Taux d'apprentissage

Le taux d'apprentissage contrôle la quantité de mises à jour des poids dans l'algorithme d'optimisation choisi. Dans notre modèle, le taux d'apprentissage initial est de 0,004. Il diminue d'un facteur de 2 après chaque 3 époques.



# Chapitre 3 : Méthodes de segmentation des vertèbres et des disques intervertébraux

## 4. Filtrage des images

Le filtrage constitue un volet important en traitement d'images, et un de ses objectifs principaux est de nettoyer l'image en éliminant le plus de bruit possible. Dans ce chapitre, nous allons nous intéresser davantage à cette classe de méthodes, et en particulier à la notion de **filtre linéaire** [21].

### 4.1 Filtres linéaires

Il existe différentes techniques de filtrage selon le type de bruit à atténuer. Le lissage par moyennage utilise un **filtre linéaire** et fait partie, en ce sens, de la classe de filtrage la plus simple [21].

### 4.2 Opérateur de convolution

Un filtre linéaire remplace la valeur de chaque pixel en entrée par une combinaison linéaire des intensités de ses pixels voisins. L'opérateur permettant d'effectuer cette transformation est appelé **produit de convolution**. C'est pourquoi l'application d'un filtre linéaire est également connue sous le terme de **filtrage par convolution**.

En notant  $*$  l'opérateur de convolution, la relation mathématique entre l'image initiale  $X$  et l'image filtrée  $Y$  pour tout type de filtre linéaire s'écrit  $Y=H*X$  Cela revient à modifier la valeur de chaque pixel.

$H$  est le **noyau (ou masque) de convolution** : il s'agit d'une matrice carrée de taille impaire  $2k+1$ , qui caractérise le filtre linéaire appliqué [21].

### 4.3 Filtres courants

Le choix des coefficients et de la taille du noyau de convolution  $H$  nous permet de définir une multitude de filtres linéaires différents. Les deux types de filtres linéaires les plus populaires sont les **filtres moyenneurs**, que nous connaissons déjà, et les **filtres gaussiens**, que nous allons étudier maintenant [21].

### 4.4 Filtres Gaussien

Un **filtre gaussien** est un filtre linéaire dont les éléments du noyau de convolution sont déterminés selon la densité d'une loi gaussienne centrée à 2 dimensions [21] :

$$h(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.1)$$

Figure 3. 2 : LOI GAUSSIENNE

#### 4.5 Filtre médian (non-linéaire)

Bien que les filtres linéaires soient faciles à concevoir et à implémenter, notamment avec la propriété de séparabilité, ils ne parviennent pas toujours à éliminer efficacement le bruit, notamment le bruit impulsionnel (par exemple, "poivre et sel"). Ces limitations ont motivé la création des **filtres non-linéaires** : il s'agit de filtres dont le fonctionnement ne peut être défini comme un produit de convolution.

Un exemple de filtre non-linéaire est le **filtre médian**, dont le principe est proche du filtre moyenneur : la valeur de chaque pixel est remplacée par la médiane (et non la moyenne) de son voisinage [21].

### 5. Segmentation par SEUILLAGE

Le seuillage représente un outil largement utilisé dans la segmentation d'image pour extraire des objets de leurs fonds en fonction d'un seuil. Tout problème de seuillage consiste alors à rechercher la valeur du seuil. La plupart des méthodes de seuillage déterminent le seuil en optimisant une fonction objective. On distingue le seuillage de base (simple) (2 classes) où le résultat du seuillage est une image binaire (0 : 1, parfois en 0 :255 pour l'affichage), et le multi-seuillage qui est utile quand on a affaire à des images qui contiennent plusieurs objets ayant des luminances différentes. Pour extraire ces objets, plusieurs seuils sont nécessaires. Le résultat du seuillage est une image avec **n+1** classes pour n seuils [23].




Figure 3. 3 : Seuillage simple d'un histogramme




Figure 3. 4 : Seuillage multiple

### 5.1 Méthodes de seuillage

Les méthodes de seuillage peuvent être réparties en deux catégories : Seuillage globale et Seuillage local ou adaptatif.

#### 5.1.1 Méthodes de seuillage globale

Les méthodes de seuillage globale reposent sur l'exploitation de l'histogramme de toute l'image. L'histogramme est une courbe monodimensionnelle qui caractérise la distribution des niveaux de gris, il est décrit par une fonction mono variable discrète  $h(i)$  ou  $p(i)$  qui représente respectivement la fréquence ou la probabilité d'apparition

du niveau de gris  $i$ , tel que :  $p(i) = \frac{h(i)}{N}$

$h(i)$  : étant le nombre de pixels ayant le niveau de gris  $i$  et  $N$  le nombre total de pixels dans l'image [32].

#### 5.1.2 Méthodes de seuillage locale ou adaptatif

A l'inverse des méthodes globales qui ne considèrent que la valeur du pixel, les méthodes locales prennent en considération la valeur des pixels voisins pour le calcul des seuils.

Les méthodes de seuillage locale sont confrontées au choix de la taille de la fenêtre de voisinage. Celle-ci doit être suffisamment petite pour préserver les détails locaux et suffisamment larges pour supprimer le bruit. [32]




Figure 3. 5 : Illustration du seuillage adaptatif

- (a) Image originale avec un fond non uniforme,
- (b) Image segmentée avec un seuil global,
- (c) Image segmentée avec un seuillage adaptatif.

Avantages :

- Trivial à implémenter.
- Très rapide

Inconvénients :

- Le seuil doit être fixé par un utilisateur.
- C'est un algorithme supervisé.
- Algorithme inefficace pour des images bruitées.

## **6. Transformations morphologiques**

Les transformations morphologiques sont des opérations qui sont normalement effectuées sur images binaire et en fonction de la forme de l'image.

L'opération exacte est déterminée par une structuration du noyau Élément qui décide de la nature de l'opération. La dilatation et l'érosion sont les deux opérateurs de base dans le domaine des transformations morphologiques.

De plus, l'ouverture et la fermeture sont deux opérations importantes, qui découlent des deux opérations (dilatation et érosion). Enfin, il existe trois autres opérations basées sur la différence entre certaines de ces opérations précédentes [33].

**6.1 Opération de dilatation**

L'effet principal d'une opération de dilatation sur une image binaire est d'étendre progressivement les régions limites de l'objet de premier plan.

Cela signifie que les zones de l'objet de premier plan deviennent plus grandes tandis que les trous à l'intérieur de ces régions rétrécissent [33].

**6.2 Opération d'érosion**

L'effet principal d'une opération d'érosion sur une image binaire est d'éroder progressivement les régions limites de l'objet de premier plan.

régions limites de l'objet de premier plan. Cela signifie que les zones de l'objet de premier plan deviennent plus petites, et les trous à l'intérieur de ces zones s'agrandissent[33].

**6.3 Opération d'ouverture**

Une opération d'ouverture réalise une érosion suivie d'une dilatation en utilisant le même élément structurant (ou noyau) pour les deux opérations. De cette façon, l'érosion peut être appliquée pour éliminer de petits groupes de pixels indésirables (par exemple, du bruit en forme de sel et de poivre).

L'érosion affectera toutes les régions de l'image sans distinction. En effectuant une opération de dilatation après l'érosion, on peut réduire certains de ces effets [33].

**6.4 Opération de fermeture**


Comme son opposé, l'opérateur de fermeture peut être dérivé des opérations d'érosion et de dilatation. Dans ce cas, l'opération effectue une dilatation suivie d'une érosion.

Une opération de dilatation est généralement utilisée pour combler les petits trous dans les images. Cependant, l'opération de dilatation va également agrandir de petits groupes de pixels indésirables. En appliquant l'opération d'érosion sur l'image, l'image après la dilatation, une partie de cet effet sera réduite [33].


On voit ci-dessus les différentes opérations appliquées sur l'image IRM de la colonne vertébrale :




A : Original.




B : Dilation.



C : Erosion.



E : Ouverture.



F : Fermeture.

Figure 3. 6 : Morphologie sur le rachis

### 7. Détection de contours

La détection des contours permet de détecter les limites des objets et de les localiser facilement dans une image. C'est souvent la première étape de nombreuses applications intéressantes, telles que l'extraction

d'images de premier plan, la segmentation d'images simples, la détection et la reconnaissance.

### **7.1 Lire l'image et la convertir au format Niveaux de gris**

Lisez l'image et convertissez-la en niveaux de gris. La conversion de l'image en niveaux de gris est très importante car elle prépare l'image pour l'étape suivante. La conversion de l'image en une image en niveaux de gris à canal unique est importante pour le seuillage, qui est à son tour nécessaire pour que l'algorithme de détection des contours fonctionne correctement.

### **7.2 Appliquer le seuillage Adaptative**

Pour trouver les contours, il faut d'abord appliquer le seuillage adaptatif ou la détection des bords de Canny à l'image en niveaux de gris. Dans notre cas, nous allons appliquer un seuillage adaptatif.

Cette opération convertit l'image en noir et blanc, mettant en évidence les objets d'intérêt pour faciliter la tâche de l'algorithme de détection des contours. Le seuillage rend le bord de l'objet de l'image complètement blanc, tous les pixels ayant la même intensité. L'algorithme peut maintenant détecter les bords des objets à partir de ces pixels blancs.

## **8. Ligne de partage des eaux (LPE ou Water shed)**

L'algorithme LPE est un algorithme classique utilisé pour la segmentation et est particulièrement utile lors de l'extraction d'objets qui se touchent ou qui se chevauchent dans des images, tels que les vertèbres de la figure ci-dessus.

En utilisant des méthodes de traitement d'image traditionnelles telles que le seuillage et la détection de contour, nous serions incapables d'extraire chaque vertèbre individuelle de l'image - mais en tirant parti de l'algorithme de bassin versant, nous sommes en mesure de détecter et d'extraire chaque vertèbre sans problème [24].



A : Image Original.



B : Image de gradient

Figure 3. 7 : Gradient sur le rachis

Le gradient morphologique permet d'obtenir les contours de tous les objets. Ici, ce que l'on souhaite, c'est obtenir le contour d'un objet spécifique.

### **8.1 Algorithme**

On pose [34] :

- I L'image relief de départ (gradient morphologique par exemple).
- M L'image des marqueurs : chaque pixel vaut soit 0 (pixel hors marqueurs) soit la valeur de l'objet auquel il appartient.
- E un élément structurant de voisinage.
- L La liste des marqueurs



## Initialisation :

Liste  $L = \phi$

$R=M$

Pour chaque  $x \in M$ ,  $L = L \cup \{(x, I(x))\}$

## Déroulement :

Tant que  $L \neq \emptyset$

Choisir  $(x, I(x)) \in L$  tel que  $I(x)$  soit minimal dans  $L$

$L = L \setminus \{(x, I(x))\}$

Pour tout  $y \in E_x$  tel que  $R(y) = 0$

$R(y) = R(x)$

$L = L \cup \{(y, I(y))\}$

## 8.2 Marqueurs

Pour fonctionner, l'algorithme a besoin d'une image de marqueurs, ou l'utilisateur aura marqué quelques pixels appartenant à l'objet et à son complémentaire [34].

Un pixel à l'intérieur du rachis.

Un pixel à l'extérieur du rachis.




Figure 3. 8 : Marqueurs sur le rachis

L'image des marqueurs permet d'apporter à l'algorithme une connaissance sur l'objet à segmenter.

## 8.3 Relief

Enfin, il nous faut une image de relief (calculée en généralement automatiquement à partir de l'image originale), ou les contours qui nous intéressent apparaissent avec

une valeur élevée. On choisit en général une image issue d'un détecteur de contours [34].





Figure 3. 9 : Gradient appliqué sur le rachis

## 8.4 Inondation

On considère l'image de relief comme un terrain topographique. On connecte des pompes qui injecteront de l'eau (de différentes couleurs) à l'endroit des marqueurs [34].



On place les pompes ici.

On place les autres pompes ici.

Figure 3. 11 : Marqueurs

## Chapitre 3 : Méthodes de segmentation des vertèbres et des disques intervertébraux

Différents lacs vont se former et grandir petit à petit. Lorsque les lacs se rencontreront, ils ne se mélangeront pas.

### **9. Post-traitement**

Bien que les segmentations obtenues avec notre approche soient généralement lisses et proches des annotations manuelles, de petites régions isolées peuvent parfois apparaître dans les résultats de segmentation finaux. Les algorithmes de régularisation utilisés dans les expériences binaires et multi-classes peuvent éliminer ces régions. Dans certains cas, les résultats peuvent montrer les régions parasites. Dans notre étude, nous visons à segmenter seulement les vertèbres et les disques intervertébraux. La ligne de partage des eaux peut améliorer la segmentation et parfois peut supprimer ces régions supplémentaires.

### **10. Conclusion**

Dans ce chapitre, nous avons présenté les étapes suivies pour la segmentation des vertèbres et des disques de la colonne vertébrale à partir d'images IRM. La méthode proposée est basée sur la combinaison d'un réseau de neurones convolutif (U-NET) avec une régularisation par la ligne partage des eaux et détection de contours. Tout d'abord, nous avons présenté les détails de l'architecture du réseau de neurones proposée. Nous avons décrit ensuite les algorithmes de régularisation que nous allons utiliser pour améliorer encore les résultats de la segmentation fournis par notre réseau de neurones. Nous avons commencé par décrire l'algorithme de ligne partage des eaux, et puis l'algorithme de détection de contours. Presque toutes les approches mentionnées dans la littérature, qui utilisent ces algorithmes de régularisation, nécessitent l'initialisation manuelle de la part d'un utilisateur.



**Chapitre 4 :**  
**Implantation Et Développement De L'approche Proposée**



## **1. Introduction**

Ce que nous avons vu dans les chapitres précédents nous a permis d'avoir une bonne compréhension de la cyphose et la lordose, de ses causes et de ses traitements, ainsi de la modélisation 3D.

Nous allons présenter dans ce chapitre l'étude et la conception de notre système. D'abord nous commencerons par l'analyse du système, ensuite nous mettrons en évidence l'étude conceptuelle de notre système présentant les différents diagrammes et descriptions en utilisant la méthode de modélisation UML. Nous décrirons également le modèle de base de données issu de notre étude.

### **1.1 Étude des documents**

L'examen des documents pris en charge par un médecin nous permet de collecter des données qui seront utilisés pour concevoir notre nouveau système. Les documents utilisés pour compléter le diagnostic sont :

- Générer une image en format NIFT et jpeg.
- Comparer une image effectuée avec son précédent.

## **2. Etude conceptuelle**

### **2.1 Cycle de développement**

Le cycle de vie est un ensemble de phases séquentiellement cohérentes, dont le nom et le nombre de séquences sont déterminés sur la base de l'étude des besoins de mise en œuvre du projet. Ce dernier représente l'étape que doit franchir le logiciel dès le début jusqu'à la fin de la conception. Ainsi, il permet de détecter et de corriger les erreurs tout au long du processus de la réalisation pour produire un logiciel de haute qualité et dans des temps et des coûts prévisibles [18] comme la montre dans la figure 4.1

- Le développement incrémental est une stratégie de mise en scène et d'ordonnancement dans laquelle diverses parties du système sont développées à des moments ou à des rythmes différents et intégrées au fur et à mesure de leur achèvement.



## Chapitre 4 : Implémentation et développement

b. Les diagrammes d'interaction : nous déploierons seulement le diagramme de séquence.

### 2.2.1 Diagramme de cas d'utilisation

Le diagramme de cas d'utilisation est la première étape de l'analyse UML, il permet de (Figure 4.2) :

- Modéliser les besoins des utilisateurs.
- Identifier les principales caractéristiques et limites du système.
- Représenter l'interaction entre le système et ses utilisateurs.

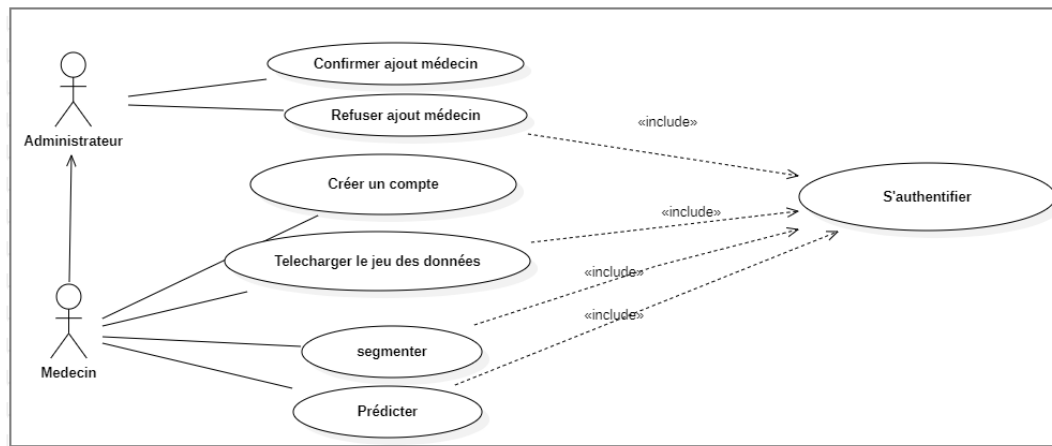


Figure 4. 2 : Diagramme de cas d'utilisation

### 2.2.2 Diagramme de séquence

Le diagramme de séquence peut représenter l'interaction entre les objets du point de vue du temps. Le point important est l'ordre chronologique d'envoi des messages. L'ordre dans lequel les messages sont envoyés est déterminé par leur position sur l'axe vertical du diagramme. Le temps s'écoule "de haut en bas" sur cet axe. La disposition des objets sur l'axe horizontal n'a aucun effet sur la sémantique du diagramme [60].

2.2.3 Authentification

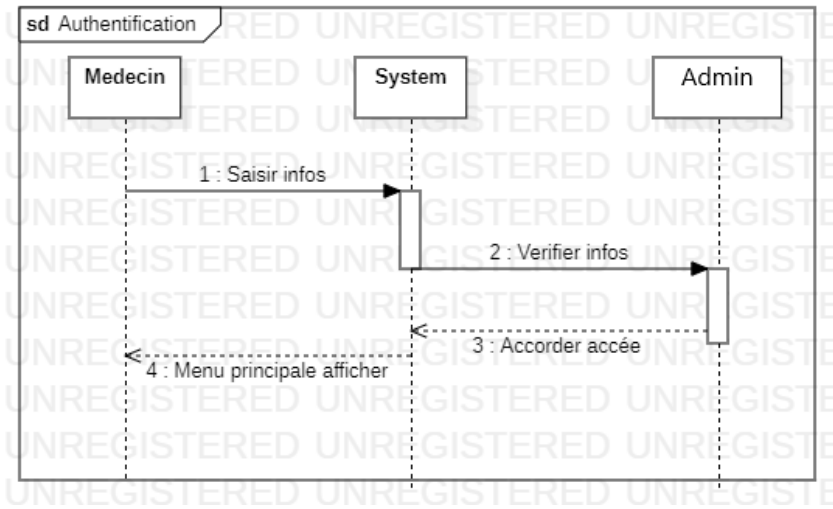


Figure 4. 3 : Authentification

2.2.4 Ajoute des données

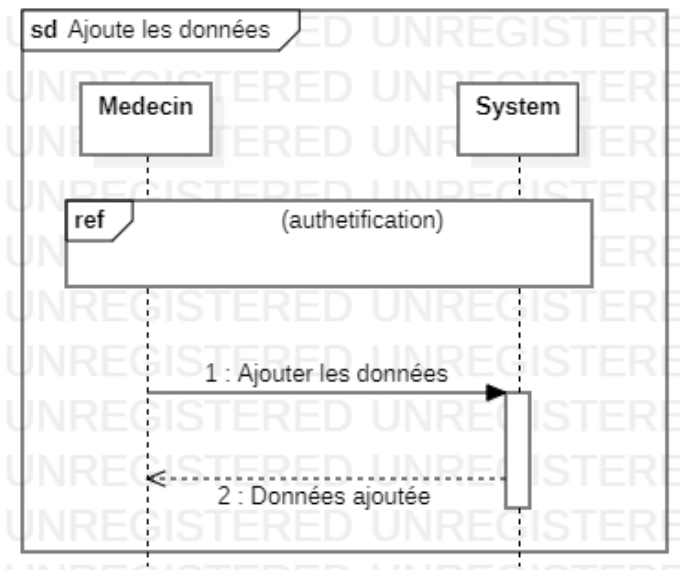


Figure 4. 4 : Ajoute les données



2.2.5 Segmentation

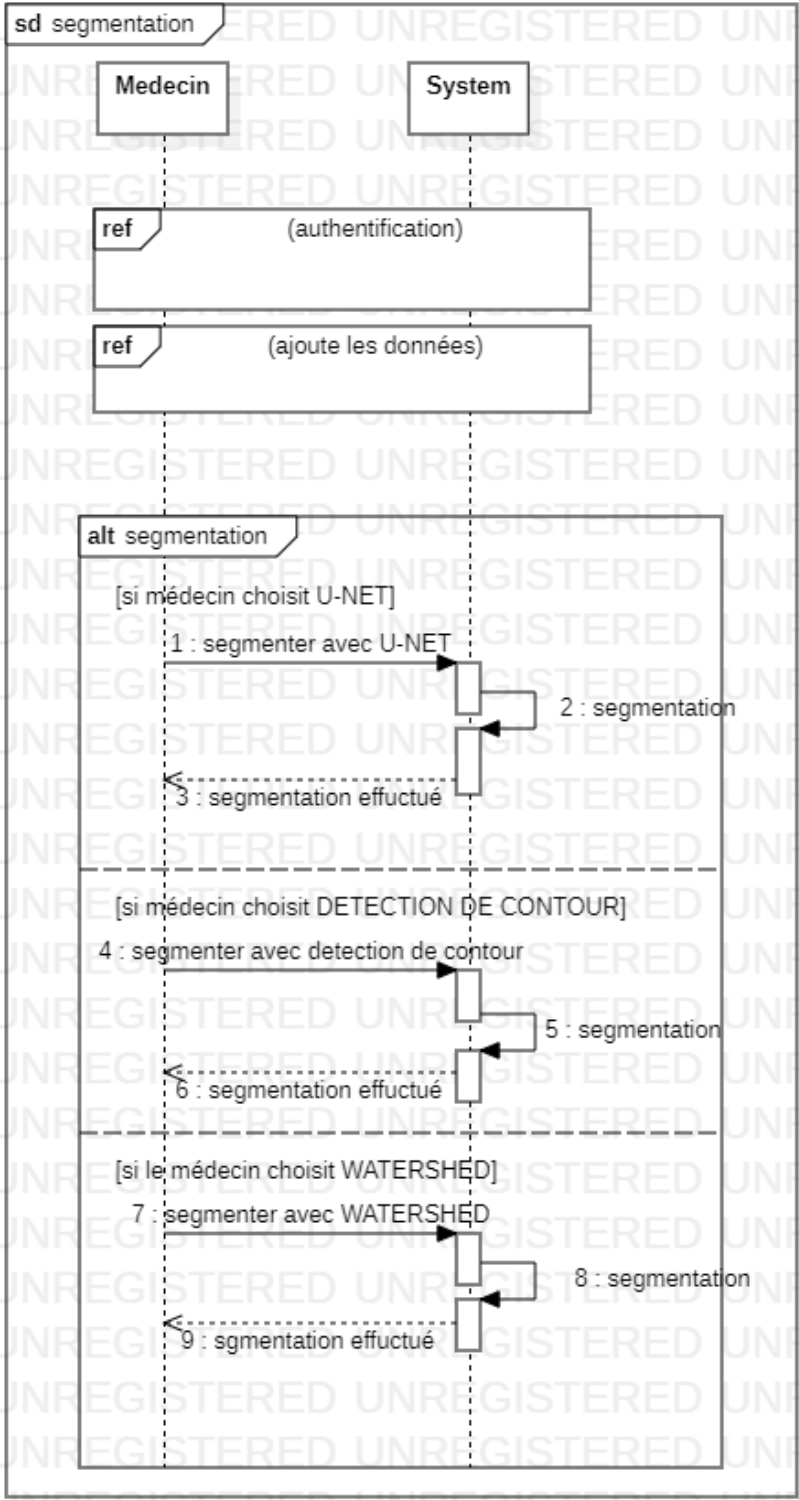


Figure 4. 5 : Segmentation de l'image.

## 2.2.6 Prédiction

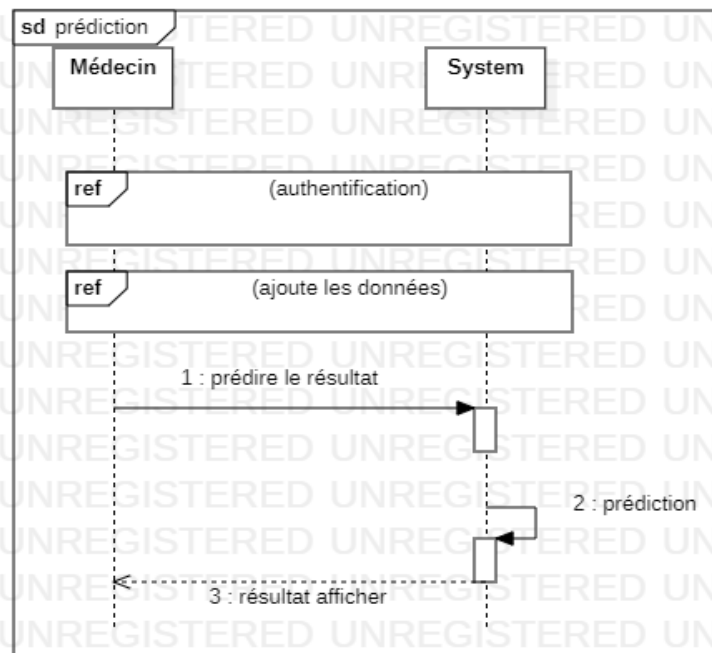


Figure 4. 6 : Prédiction

## 2.2.7 Diagramme de classes

Le diagramme de classes décrit les types d'objets qui composent le système ainsi que les différents types de relations statiques entre ces objets. Ainsi, il représente également le comportement du système [60] comme illustré dans la figure 10.7.




Figure 4. 7 : Diagramme de Class

## **3. Conclusion**

Pour conclure ce chapitre, nous nous sommes penchés sur l'analyse et la conception de notre système. Les schémas conceptuels et la base de données utilisée dans cette étude ont été décrits. Dans le chapitre qui suit, nous allons procéder à la description de nos contributions.



**Chapitre 5 : Mise en oeuvre du système  
HEALTHCARE**



# Chapitre 5 : Mise en œuvre du système HEALTHCARE

## 1. Introduction

Dans ce chapitre, nous allons exposer les outils de développement et les langages utilisés pour développer la solution proposée, nous abordons après les détails de la mise en œuvre du réseau. Ensuite, nous décrivons les paramètres d'évaluation utilisés pour évaluer les résultats de la segmentation. Pour démontrer l'efficacité de notre approche, nous présenterons dans la suite les résultats expérimentaux de la base de données d'images IRM 3D. La base de données contient la segmentation manuelle des vertèbres.

## 2. Détails d'implémentation

La méthode de segmentation proposée est basée sur une architecture de réseau de neurones entièrement convolutif à deux dimensions(U-NET). Cette architecture est composée de 24 couches au total avec la disposition suivante : 18 couches de convolution. Pour les deux premières couches, nous avons utilisé 32 filtres de taille (3×3) dans chaque couche. Dans les deux couches de convolution suivantes, nous avons utilisé 64 filtres de taille (3×3) dans chaque couche. Ensuite pour les deux couches de convolution suivantes, nous avons utilisé 128 noyaux de taille (3×3) sont utilisés dans chaque couche 128 noyaux de taille (3×3) sont utilisés dans chaque couche. Dans les deux couches de convolution suivantes, nous avons utilisé 256 filtres de taille (3×3) dans chaque couche.

Après en passe à la phase de décodage la première couche est la déconvolution plus deux couches de convolution, nous avons utilisé 128 filtres de taille (3×3) dans chaque couche. Ensuite on a une couche déconvolution plus deux couches de convolution, nous avons utilisé 64 noyaux de taille (3×3) sont utilisés dans chaque couche. Et enfin, on a une couche de déconvolution plus deux couches de convolution, nous avons utilisé 32 noyaux de taille (3×3) sont utilisés dans chaque couche.

Après chaque convolution on a utilisé la fonction ReLU pour désactiver tous les nœuds qui possède des valeurs négative, Cela rend très efficace sur le plan du calcul car peu de neurones sont activés à la fois, et à la fin de chaque phase on a appliqué un max-pooling ça nous a aidé à extraire des caractéristiques nettes et lisses. Cela

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

permet également de réduire la variance et les calculs. Le max-pooling permet d'extraire des caractéristiques de bas niveau comme les bords, les points, etc.

Au lieu d'utiliser l'image 3D entier comme entrée, notre réseau extrait de l'image originale des segments bidimensionnels de petite taille et les utilise comme entrée. Cette stratégie réduit les besoins en mémoire et augmente considérablement le nombre d'échantillons d'apprentissage.

Pour mettre en œuvre notre réseau, nous avons adapté l'architecture du U-NET développé par (Olaf Ronneberger, Philipp Fischer, Thomas Brox a (2015)). Le modèle a été formé et testé sur une unité de traitement graphique GPU Vega11. Les algorithmes de la ligne de partage des eaux et détection de contours ont été développés sur python. L'ordinateur utilisé pour exécuter ces algorithmes est un processeur Amd Rayzen 5 3400G à 4,2 GHz.

L'apprentissage de notre réseau sur la base de données des vertèbres prend environ 10 minutes par époque et environ 1 heures au total. La segmentation d'un sujet nécessite environ 30 secondes.

### **2.1 Bases de données**

La base de données, accessible au public, est constituée de 514 images IRM 3D spin-écho pondérées en T2 de façon sagittale provenant de 514 sujets différents. Les images ont été acquises à l'aide d'un scanner Siemens Tesla 1.5 et ré-échantillonnées à une taille de voxel de  $2 \times 1,25 \times 1,25 \text{ mm}^3$ . Toutes les images sont échantillonnées pour avoir les mêmes tailles de  $39 \times 320 \times 320$  voxels. Chaque image contient au moins 8 corps vertébraux de la colonne vertébrale inférieure (T11 - L5). Pour chaque corps vertébral, 4112 vertèbres au total, une segmentation manuelle de référence est fournie sous la forme d'un masque binaire. Toutes les images et tous les masques binaires sont stockés dans le format de fichier NIFTI (Neuroimaging Informatics Technology Initiative)

### **2.2 Les résultats de la segmentation de U-NET**

Le code U-Net que nous avons utilisé prend comme entrée des images carrées bidimensionnelles de taille  $320 \times 320$  avec une plage d'intensité de pixel allant de 0 à 255. Dans la base de données de vertèbres, la plage d'intensité de pixel varie de -251 à 1500 et la taille spatiale des images est de  $39 \times 320$ . Donc, pour utiliser ce

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

code, les images doivent être normalisées et redimensionnées. Nous avons d'abord normalisé les images afin que les intensités de pixels soient comprises entre 0 et 255, puis nous avons divisé le volume 3D de chaque sujet en images 2D. Le code a été développé avec KERAS. L'apprentissage a été exécuté sur 5 époques en utilisant une entropie croisée binaire comme fonction de perte. Les sorties du réseau sont des probabilités sigmoïdes sur une carte de taille 320 x 320. La sortie finale est convertie en une image binaire étiquetée à un seuil de 0,5. Le réseau a été appris 514 fois, à chaque fois nous avons utilisé 414 sujets d'apprentissage en laissant 100 sujets pour le test.

En termes de durée, le réseau a pris quelques heures pour l'apprentissage et quelques secondes pour le test. Qualitativement, les résultats segmentation sont acceptables et montrent clairement la forme des corps vertébraux et l'anatomie de la colonne.

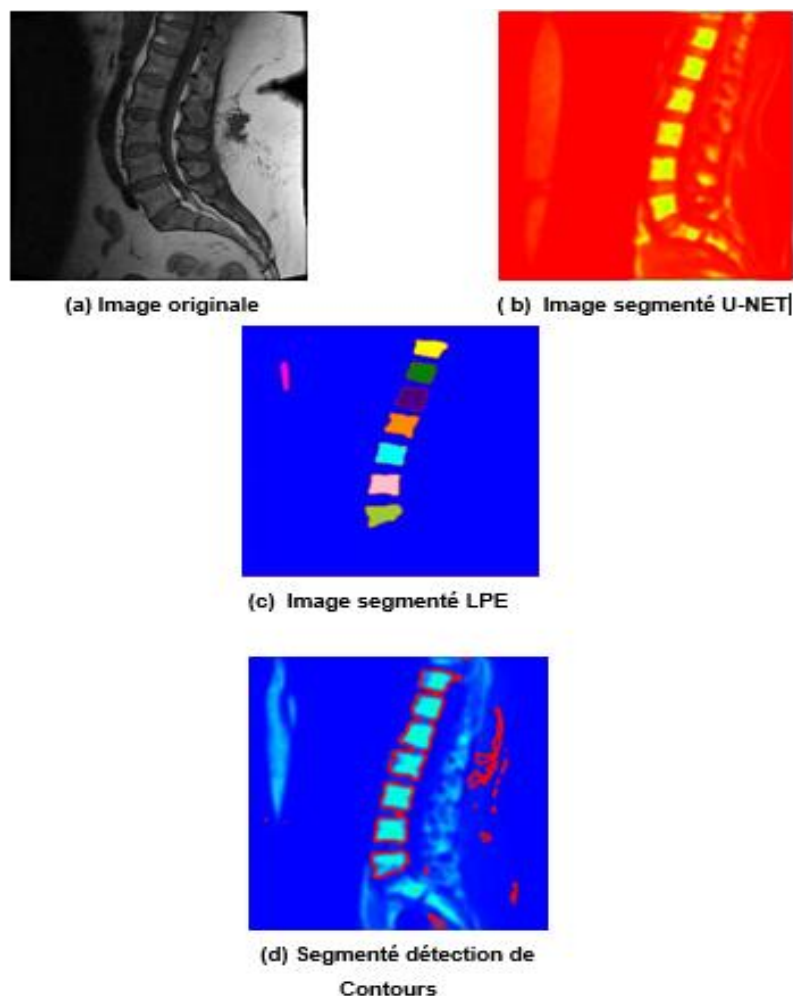


Figure 5.1 : Différentes segmentation obtenue

```
Epoch 1/5
207/207 [=====] - 163s 786ms/step - loss: 0.0417 - accuracy: 0.9386 - val_loss: 0.0047 - val_accuracy:
0.9491
Epoch 2/5
207/207 [=====] - 163s 787ms/step - loss: 0.0052 - accuracy: 0.9426 - val_loss: 0.0047 - val_accuracy:
0.9491
Epoch 3/5
207/207 [=====] - 163s 790ms/step - loss: 0.0051 - accuracy: 0.9428 - val_loss: 0.0046 - val_accuracy:
0.9489
Epoch 4/5
207/207 [=====] - 163s 790ms/step - loss: 0.0050 - accuracy: 0.9429 - val_loss: 0.0046 - val_accuracy:
0.9493
Epoch 5/5
207/207 [=====] - 166s 800ms/step - loss: 0.0050 - accuracy: 0.9429 - val_loss: 0.0045 - val_accuracy:
0.9486
```

Figure 5.2 : La précision et la perte de notre modèle

La figure 4.5 illustre les résultats visuels de la segmentation du sujet sélectionné sur le plan sagittal selon différentes méthodes. La première ligne de la figure montre le résultat de la segmentation obtenu par l'architecture U-NET. Ce réseau était capable d'identifier la forme de la colonne vertébrale, mais le résultat n'était pas précis et certaines vertèbres n'étaient pas complètement segmentées et on a aussi des informations perturbantes. Une précision de 94,86% a été obtenu pour ce sujet. La deuxième ligne de la figure montre le résultat de la segmentation obtenu par notre ligne de partage des eaux. Les vertèbres sont bien identifiées et la segmentation ne contient aucune fausse prédiction ce qui représente une amélioration par rapport à U-NET, L'algorithme de ligne de partage des eaux améliore également le résultat de la segmentation primaire obtenue par notre réseau, dans la troisième pour la détection de contours ce qui améliore aussi le résultat de la segmentation primaire obtenue par notre réseau.

### **3. Outils de rédaction et de conception**

#### **3.1 Word version 2019**

Word est le logiciel phare de la suite Bureautique Microsoft Office. C'est l'un des logiciels les plus utilisés dans le monde et permet de rédiger des lettres, CV, rapports et tous types de documents texte. Word permet de mettre en page vos documents,



# Chapitre 5 : Mise en œuvre du système HEALTHCARE

de générer des sommaires, de numéroter automatiquement des pages, corriger la grammaire et l'orthographe, de créer des schémas, de faire du publipostage [79].

## 3.2 StarUML

StarUML est un projet open source pour développer une plate-forme UML / MDA rapide, flexible, extensible, fonctionnelle et disponible gratuitement fonctionnant sur la plate-forme Win32. L'objectif est un remplacement convaincant des outils UML commerciaux tels que RationalRose17, Together18 [77].

## 4. Outils de développement

### 4.1 Matériel utilisé

L'implémentation de nos codes, a été réalisée, grâce à deux PC :

- laptop : Un processeur Intel® Core™ i3 écran 15.6", Windows 10 Pro, type de mémoire DDR3L 256Go avec 8 Go de RAM et carte Graphics intégré.
- ordinateur (Pc fixe) : Un processeur AMD Ryzen™ 5 3400G, écran 14.0", type de mémoire SSD256 GO avec 16 Go de RAM et carte Graphics AMD VEGA 11.

### 4.2 Python

Python est un langage de programmation interprété, orienté objet, de haut niveau et doté d'une sémantique dynamique. Ses structures de données intégrées de haut niveau, combinées au typage dynamique et à la liaison dynamique, le rendent très attrayant pour le développement rapide d'applications, ainsi que pour une utilisation en tant que langage de script ou de colle pour connecter des composants existants. La syntaxe simple et facile à apprendre de Python privilégie la lisibilité et réduit donc le coût de la maintenance des programmes. Python supporte les modules et les packages, ce qui encourage la modularité des programmes et la réutilisation du code. L'interpréteur Python et la bibliothèque standard étendue sont disponibles gratuitement sous forme de source ou de binaire pour toutes les principales plateformes et peuvent être distribués librement [80].

### 4.3 SLICER

3D Slicer (Slicer) est un logiciel libre et gratuit d'analyse d'images et de visualisation scientifique. Slicer est utilisé dans une variété d'applications médicales, notamment

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

l'autisme, la sclérose en plaques, le lupus érythémateux systémique, le cancer de la prostate, le cancer du poumon, le cancer du sein, la schizophrénie, la biomécanique orthopédique, les maladies cardiovasculaires et la neurochirurgie aussi que les différentes pathologies du rachis [81].

### 4.4 Flask

Flask est un Framework web. Cela signifie que Flask vous fournit des outils, des bibliothèques et des technologies qui vous permettent de construire une application web. Cette application web peut être quelques pages web, un blog, un wiki ou aller aussi loin qu'une application web de calendrier ou un site web commercial.

Flask fait partie des catégories de micro-Framework. Les micro-frames sont normalement des Frameworks avec peu ou pas de dépendances à des bibliothèques externes [83].

### 4.5 Jinja

Jinja est un moteur de modèles web pour le langage de programmation Python. Il a été créé par Armin Ronacher et est sous licence BSD. Jinja est similaire au moteur de modèles de Django mais fournit des expressions de type Python tout en garantissant que les modèles sont évalués dans une sandbox. Il s'agit d'un langage de modèles basé sur le texte et peut donc être utilisé pour générer n'importe quel balisage ainsi que du code source.

Le moteur de modèles Jinja permet de personnaliser les balises, les filtres, les tests et les globaux. De plus, contrairement au moteur de modèles Django, Jinja permet au concepteur de modèles d'appeler des fonctions avec des arguments sur des objets. Jinja est le moteur de modèles par défaut de Flask et il est également utilisé par Ansible, Trac et Salt [84].

### 4.6 Mongo dB

MongoDB est un programme de gestion de base de données NoSQL open source. NoSQL est utilisé comme une alternative aux bases de données relationnelles traditionnelles. Les bases de données NoSQL sont très utiles pour travailler avec de grands ensembles de données distribuées. MongoDB est un outil qui permet de gérer des informations orientées documents, de stocker ou de récupérer des informations.

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

MongoDB prend en charge différentes formes de données. C'est l'une des nombreuses technologies de bases de données non relationnelles qui ont vu le jour au milieu des années 2000 sous la bannière NoSQL - normalement, pour être utilisée dans les applications big data et autres travaux de traitement impliquant des données qui ne s'intègrent pas bien dans un modèle relationnel rigide. Au lieu d'utiliser des tables et des lignes comme dans les bases de données relationnelles, l'architecture MongoDB est constituée de collections et de documents [85].

### 4.7 HTML

HyperText Markup Language, HTML, is a type of descriptive computer language. More precisely, it is a data format used in the Internet world for the formatting of Web pages. It allows, among other things, to write hypertext, but also to introduce multimedia resources in a content [86].

### 4.8 CSS

Les feuilles de styles sont un langage qui permet de gérer la présentation d'une page Web. Le langage CSS est une recommandation du World Wide Web Consortium (W3C), au même titre que HTML ou XML [87].

### 4.9 JavaScript

JavaScript est un langage de programmation informatique dynamique. Il est léger et le plus souvent utilisé dans le cadre de pages Web, dont les implémentations permettent au script côté client d'interagir avec l'utilisateur et de créer des pages dynamiques. Il s'agit d'un langage de programmation interprété avec des capacités orientées objet.

JavaScript était d'abord connu sous le nom de LiveScript, mais Netscape a changé son nom en JavaScript, peut-être en raison de l'engouement suscité par Java. JavaScript a fait sa première apparition dans Netscape 2.0 en 1995 sous le nom de LiveScript. Le noyau polyvalent du langage a été intégré dans Netscape, Internet Explorer et d'autres navigateurs Web [88].

### 4.10 Open CV

Open CV (Open Source Computer Vision Library) est une bibliothèque de logiciels open source de traitement d'images et d'apprentissage automatique. Open CV est

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

conçu pour fournir une infrastructure commune pour les applications de vision et accélérer l'utilisation de la perception de la machine dans les produits commerciaux. Étant un produit sous licence BSD, Open CV facilite l'utilisation et la modification du code par les entreprises [78].

### **5. Aperçu de notre application HEALTHCARE**

Notre application offre les services suivants :

1. Traitement du rachis :
  - ✓ La segmentation du rachis avec WATERHSED.
  - ✓ La segmentation du rachis avec U-NET.
  - ✓ La détection de contour sur le rachis
  - ✓ La prédiction du résultat.
2. Aux médecins :
  - ✓ Authentification du médecin.

#### **5.1 Authentification**

Lorsque l'application est lancée, une fenêtre s'affiche en demandant l'adresse mail et un nom d'utilisateur et un mot de passe. La figure 10.8 représente l'interface de l'application.

# Chapitre 5 : Mise en œuvre du système HEALTHCARE

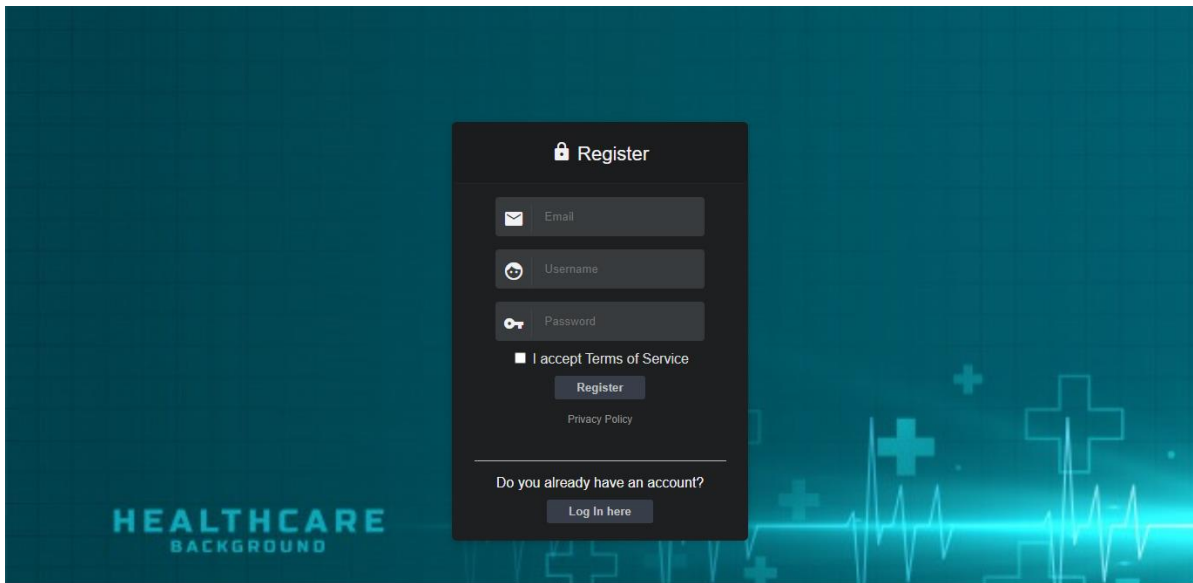


Figure 5. 3 : Authentification

## 5.2 Connexion

En suit après authentification le médecin doit il connecté a son compte comme la figure suivante :

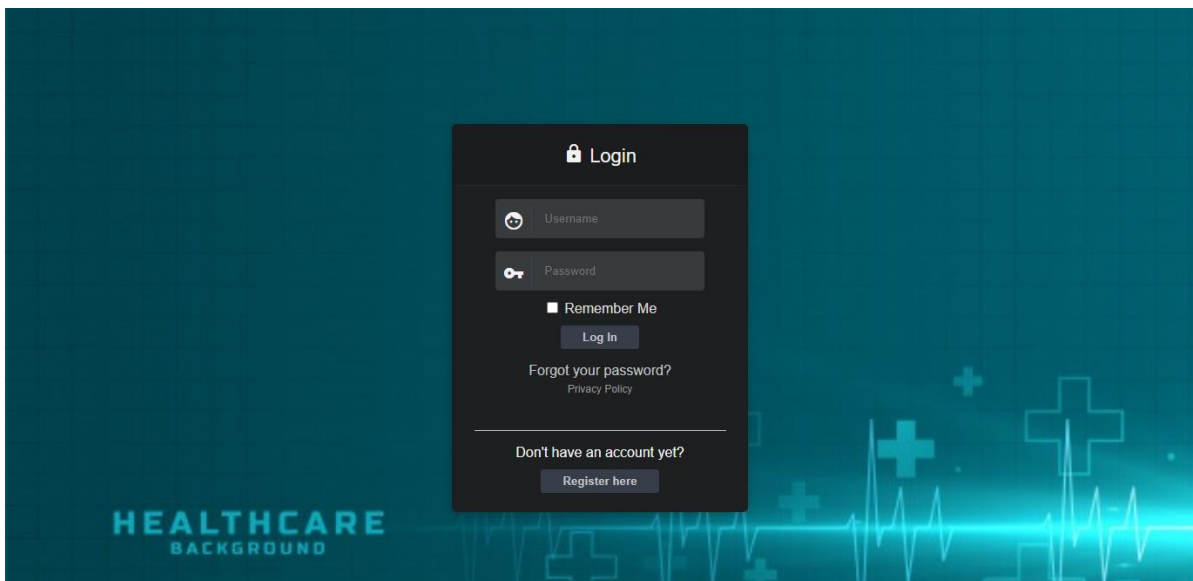


Figure 5. 4 : Connexion

# Chapitre 5 : Mise en œuvre du système HEALTHCARE

## 5.3 Menu principale

Ce menu permet à l'utilisateur de choisir l'une des fonctionnalités que l'utilisateur veut effectuer (Figure 5.3).

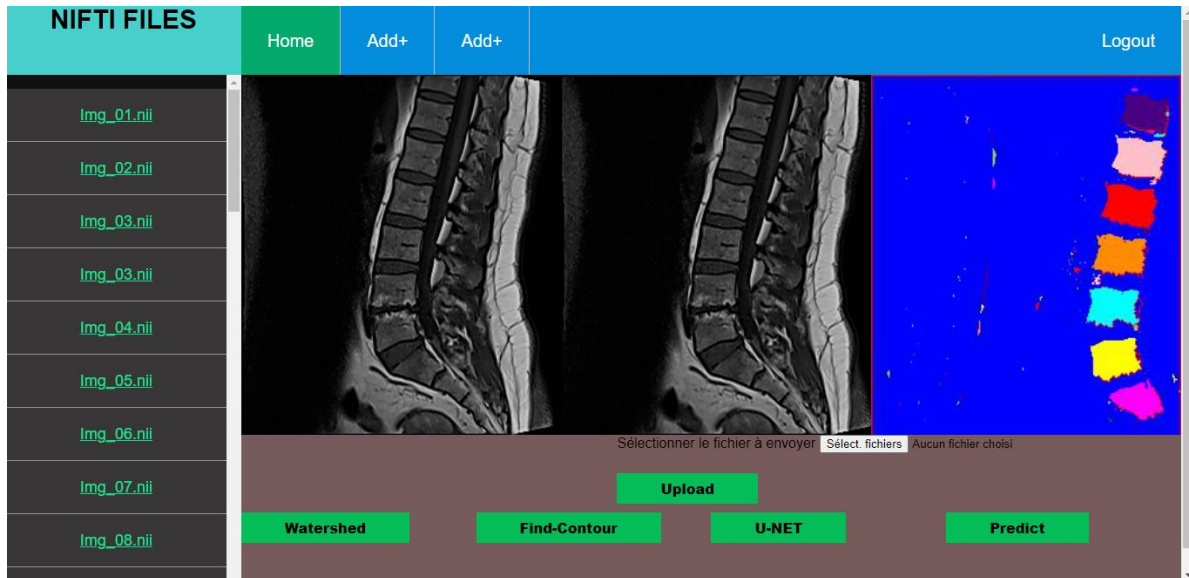


Figure 5. 5 : Menu principal

## 5.4 Téléchargement des données

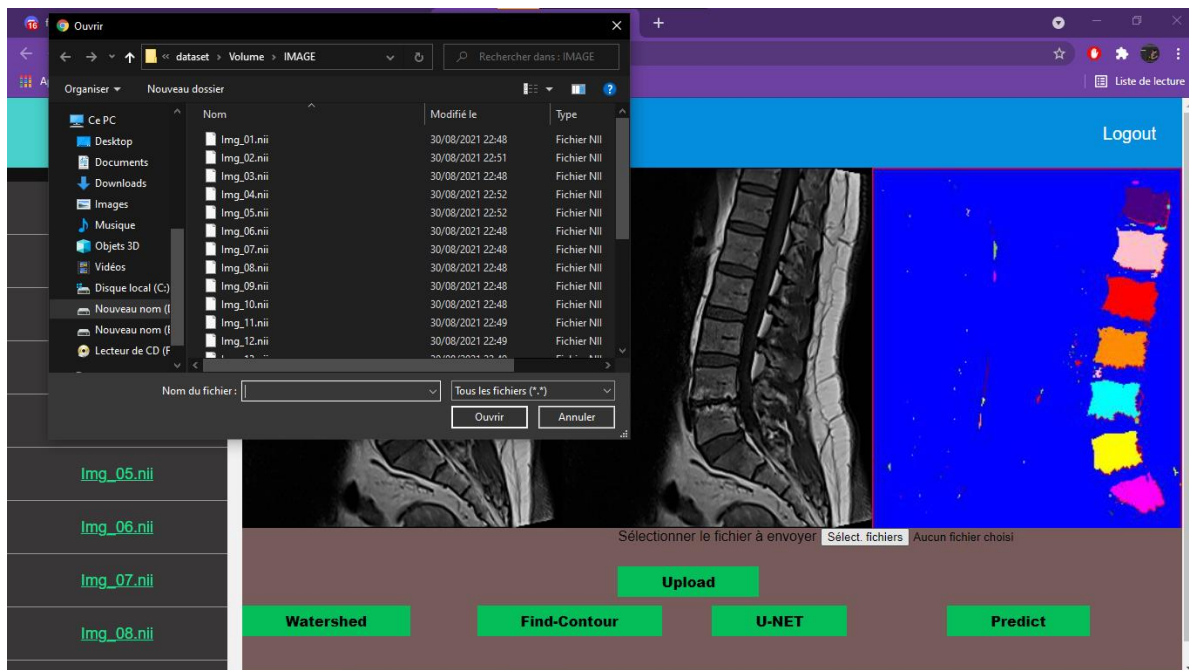


Figure 5. 6 : Téléchargement des données

## Chapitre 5 : Mise en œuvre du système HEALTHCARE

### 6. Conclusion

Ce chapitre est dédié à la réalisation de notre projet. Nous avons introduit des outils d'écriture, de conception et de développement, ainsi que des langages de programmation et leurs bibliothèques principales. Nous avons également détaillé les principales fonctionnalités de notre application via des captures d'écran.

# Conclusion Générale et perspectives

L'évaluation quantitative de la lordose et de la cyphose idiopathique ne doit être réalisée en routine que si elle est fiable et rapide.

La première partie de ce travail nous a permis de maîtriser Le contexte médical ainsi que les travaux se référant à la lordose et à la cyphose, et les solutions proposées à ces maladies.

Nous avons identifié cette maladie et identifié l'incertitude de mesure dans des contextes cliniques de routine chez les patients présentant des anomalies de la colonne vertébrale.

Dans le chapitre suivant, l'étude bibliographique nous a permis de définir des méthodes de segmentation des disques intervertébraux et des disques intervertébraux et de détailler leur fonctionnement. Nous avons également brièvement présenté le résultat obtenu, donnant ainsi quelques exemples obtenus à partir de ce résultat.

Ensuite, nous nous sommes intéressés aux réseaux de neurones, où nous avons exposé les concepts théoriques pour une bonne compréhension de ces derniers et leurs utilisations dans divers domaines.

Le but de la première partie est de partager ses connaissances avec la deuxième partie.

Dans la deuxième partie, l'étude bibliographique nous place d'abord dans l'objectif de notre travail.

Nous avons démontré et détaillé des techniques de modélisation Et les algorithmes utilisés pour réaliser le projet dans cette partie.

Nous avons ensuite pu appliquer tous les tests à un groupe de personnes atteintes de lordose et de cyphose.

En conclusion, les résultats de nos travaux sur la conception et la réalisation d'une application web ont démontré que l'IRM permet aujourd'hui en pratique clinique l'analyse quantitative 2D/3D fiable, universelle et rapide des anomalies de la lordose et de la cyphose permanente.

Nous avons également pu perfectionner l'environnement Spyder et V-studio et leurs outils de développement en créant notre application grâce à l'IA.



## Chapitre 5 : Mise en œuvre du système HEALTHCARE

La mise en œuvre de tels projets nécessite beaucoup de connaissances. Malgré cela et malgré de nombreux problèmes de formation et de développement, grâce à un travail d'équipe acharné et une organisation soignée, nous avons réussi à atteindre notre objectif de diagnostic complet des patients avec ou sans ces dernières maladies.

Nous avons eu beaucoup de problèmes et malgré le peu de temps que nous avons consacré aux soins de santé, il n'y en avait pratiquement plus. Nous prévoyons de l'améliorer dans un proche avenir En ajoutant des disques intervertébraux.

De plus, nous espérons que ce travail sera utile pour ceux qui souhaitent aborder des sujets similaires et que notre application pourra déjà être utilisée par les médecins.



## **Bibliographie**



- [1] : En ligne : Espace Francilien Du Rachis/Pathologies Problèmes De Dos. Valable Sur : <https://Rachis.Paris/Pathologies-Problemes-De-Dos/Le-Rachis-Cervical>.  
[Consulté Le 1 Juin 2021].
- [2] : Jean-Philippe Dillenseger « Atlas D'anatomie Générale Et Radiologique-ELSEVIER-MASSON » (2011).
- [3] : Abelin-Genevois « Rachis Equilibre Sagittal » 17-09-2014 [27]
- [4] : En ligne : Ingrid Haberfeld « Journal Des Femmes/Fiche Des Malades ». Valable Sur:<https://Sante.Journaldesfemmes.Fr/Fiches-Maladies/2682469-Lordose-Cervicale-Physiologique-Symptome-Normale-Inversee-Traitement-Redressement/>,  
[Consulté Le 1 Juin 2021].
- [5] : En ligne : FUTURA SANTÉ. Valable Sur <https://www.futura-sciences.com/sante/definitions/medecine-lordose-cervicale-13370/>,  
[Consulté Le 1 Juin 2021].
- [6] : En ligne : REFLEX OSTEO « Reflexosteo/Blog-Sante-Bien-Etre/Lordose-Cervicale-Et-Cervicalgie ». Valable Sur <https://www.reflexosteo.com/blog-sante-bien-etre/lordose-cervicale-et-cervicalgie-141> , [Consulté Le 1 Juin 2021].
- [7] : En ligne : Alexandra Pihen « Passeport Santé/Maux/Problèmes ». Valable Sur : <https://www.passeportsante.net/maux/problemes> , [Consulté Le 1 Juin 2021].
- [8] Pr SM BOUKERCHE « Service d'Anatomie Appliquée EHU Cours Rachis Oran [2013/2014] ».
- [9] : En ligne : Journal Sante Science Valable Sur : <https://www.santescience.fr/symptomes/cyphose/>, [Consulté Le 1 Juin 2021].
- [10] : En ligne : Journal ELSAN CMC TRONQUIÉRES Valable Sur : <https://www.elsan.care/fr/nos-actualites/cyphose-dorsale-comment-corriger-un-dos-courbe>, [Consulté Le 1 Juin 2021].
- [11] : En ligne : Cleveland Clinic Valable sur <https://my.clevelandclinic.org/health/diseases/17671-kyphosis>, [Consulté Le 1 Juin 2021].
- [12] : En ligne : Dr F. Reinaud « Clinique Concilio //Rhumatologie-Pathologies-Du-Rachis-Lordose » Valable Sur : <https://www.concilio.com/rhumatologie-pathologies-du-rachis-lordose>,  
[Consulté Le 1 Juin 2021].
- [13] A. Benrabia, « Recalage Et Mise En Correspondance D'images » Université Des Sciences Et De La Technologie Houari Boumediene, Alger, 2019.
- [14] BENDALI BRAHAM HACIBA Et TAFIGHOULT MARIA « Conception Et Réalisation D'une Application Mobile Pour Augmenter Une Image Radiographique ».
- [15] M. Diaz, « Scoliose Idiopathique Opérée, Evolution De L'équilibre, » Médecine Humaine Et Pathologie, 2019.

- [16] A. Marchand, « UML Pour Le Temps-Réel Et L'embarqué » Ecole Polytechnique De L'Université De Nantes, 2005-2006.
- [17] A. Cockburn, « Using Both Incremental And Iterative Development » Software Engineering Technology, 2008.
- [18] Z. S Ameur, « Revue Des Approches De Segmentation » Laboratoire D'analyse Et De Modélisation Des Phénomènes Aléatoires, Tizi-Ouzou, 2005.
- [19] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun « Computer Vision And Pattern Recognition »
- [20] Karen Simonyan, Andrew Zisserman « Computer Vision And Pattern Recognition »
- [21] : En ligne : Plateforme Open Classroom Cour Classifier Et Segmentez Des Données Visuelles, Valable Sur :<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/4470538-comprenez-comment-un-ordinateur-voit-une-image>, [Consulté Le 10 Juillet 2021].
- [22] L. Lechlek, M. Ghogal. 2012 « la Segmentation D'image Médicale Par La Méthode D'ensemble De Niveaux (Level Sets) ». Thèse de Master, Université Larbi Ben M'hidi Oum El Bouaghi.
- [23] M. Sandeli. 2014 « Traitement D'images Par Des Approches Bio-Inspirées ». Thèse De Magister, Université Constantine 2
- [24] : En ligne : plateforme Imagesearch valable en ligne sur : <https://www.pyimagesearch.com/2015/11/02/watershed-opencv/>, [Consulté Le 10 Juillet 2021].
- [25] : En ligne : plateforme bodysecure valable en ligne sur : <https://body-secure.fr/blogs/blog-mal-de-dos/cyphose-dorsale-cervicale-lombaire>, [Consulté le 10 juillet 2021].
- [26] A. Krähenbühl. 2014 « Segmentation Et Analyse Géométrique Application Aux Images Tomodensitométriques De Bois ». Thèse De Doctorat, École Doctorale IAEM Lorraine.
- [27] Séverine Dubuisson, « Détection De Contour Dans Les Images ».
- [28] H. MAITRE, (2004). « Le Traitement Des Images ».
- [29] A. Bitam 2013 « analyse Et Segmentation D'image Multispectrales, Application Aux Images MSG » Thèse De Doctorat, UNIVERSITE MOULOUD MAMMERI DE TIZI-OUZOU.
- [30] J.C. Baillie (2003). « Cours De Segmentation Module D9 Traitement D'images Et Vision Artificielle ». ENSA.
- [31] M. Meliani 2012 « Segmentation d'Image Par Coopération Régions-Contours ». Thèse De Magister, Ecole Nationale Supérieure En Informatique, Oued-SMAR Alger, Ecole Doctorale STIC.

- [32] W. ABDELLI OUARDIA. 2011 « Segmentation D'images Par Seuillage D'histogrammes Bidimensionnels ». Thèse De Magister, UNIVERSITE MOULOU D MAMMERI DE TIZI-OUZOU.
- [33] ALBERTO FERNANDEZ VLLAN « Mastering OpenCv 4 With Python ».
- [34] JOHN CHAUSSARD « Cours Segmentation D'image Université Paris 13 ».
- [35] Abdel-Hamid, O., Mohamed, A.-R., Jiang, H., Deng, L., Penn, G. & Yu, D. (2014). « Convolutional Neural Networks For Speech Recognition. IEEE/ACM Transactions On Audio, Speech,And Language Processing », 22(10), 1533–1545.
- [36] Hannun, A., Case, C., Casper, J., Catanzaro, B., Diamos, G., Elsen, E., Prenger, R., Satheesh, S., Sengupta, S., Coates, A. Et Al. (2014). « Deep Speech Scaling Up End-To-End Speech Recognition ». Arxiv Preprint Arxiv 1412.5567.
- [37] Graves, A. & Jaitly, N. (2014). « Towards End-To-End Speech Recognition With Recurrent Neural Networks. International Conference On Machine Learning», Pp. 1764–1772.
- [38] Lawrence, S., Giles, C. L., Tsoi, A. C. & Back, A. D. (1997). « Face Recognition A Convolutional Neural-Network Approach. IEEE Transactions On Neural Networks», 8(1), 98–113.
- [39] Parkhi, O. M., Vedaldi, A., Zisserman, A. Et Al. (2015). « Deep Face Recognition ». BMVC, 1(3),6.
- [40] Krizhevsky, A., Sutskever, I. & Hinton, G. E. (2012). « Imagenet Classification With Deep Convolutional Neural Networks. Advances In Neural Information Processing Systems», Pp. 1097–1105.
- [41] Hu, J., Shen, L. & Sun, G. (2017). « Squeeze-And-Excitation Networks ». Arxiv Preprint Arxiv 1709.01507.
- [42] Girshick, R., Donahue, J., Darrell, T. & Malik, J. (2014). « Rich Feature Hierarchies For Accurate Object Detection And Semantic Segmentation. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition », Pp. 580–587. Gonzalez, R. C. & Woods, R. E. (2002). Thresholding. Digital
- [43] He, K., Zhang, X., Ren, S. & Sun, J. (2015). « Delving Deep Into Rectifiers Surpassing Humanlevel Performance On Imagenet Classification. Proceedings Of The IEEE International Conference On Computer Vision », Pp. 1026–1034.
- [44] Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (2016). You Only Look Once Unified, « Real-Time Object Detection. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition», Pp. 779–788.
- [45] : En ligne : Andrej Karpathy, S. C. C. (2018, Janvier). « CS231n Convolutional Neural Networks For Visual Recognition ». Repère A [Http//Cs231n.Github.io/Neural-Networks-1/](http://Cs231n.Github.io/Neural-Networks-1/).

- [46] Al Arif, S. M. M. R., Knapp, K. & Slabaugh, G. (2018). « Shape-Aware Deep Convolutional Neural Network For Vertebrae Segmentation. Computational Methods And Clinical Applications In Musculoskeletal Imaging », Pp. 12–24.
- [47] He, K., Zhang, X., Ren, S. & Sun, J. (2016). « Deep Residual Learning For Image Recognition. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition », Pp. 770–778.
- [48] Maas, A. L., Hannun, A. Y. & Ng, A. Y. (2013). « Rectifier Nonlinearities Improve Neural Network Acoustic Models ». Proc. Icml, 30(1), 3.
- [50] Nair, V. & Hinton, G. E. (2010). « Rectified Linear Units Improve Restricted Boltzmann Machines ». Proceedings Of The 27th International Conference On Machine Learning (ICML- 10), Pp. 807–814.
- [51] Xu, B., Wang, N., Chen, T. & Li, M. (2015). « Empirical Evaluation Of Rectified Activations In Convolutional Network ». Arxiv Preprint Arxiv 1505.00853.
- [52] Lin, M., Chen, Q. & Yan, S. (2013). « Network In Network ». Arxiv Preprint Arxiv 1312.4400.
- [52] Lecun, Y., Bottou, L., Bengio, Y. & Haffner, P. (1998). « Gradient-Based Learning Applied To Document Recognition ». Proceedings Of The IEEE, 86(11), 2278–2324.
- [53] : En ligne : Shipra Saxena Platform Analytics Vidhya  
<https://www.analyticsvidhya.com/blog/2021/03/the-architecture-of-lenet-5/>,  
 [Consulté Le 10 Juillet 2021].
- [54] Cire, San, D. C., Meier, U., Gambardella, L. M. & Schmidhuber, J. (2010). Deep, Big, « Simple Neural Nets For Handwritten Digit Recognition. Neural Computation », 22(12), 3207–3220.
- [55] Zeiler, M. D. & Fergus, R. (2014). « Visualizing And Understanding Convolutional Networks. European Conference On Computer Vision, Pp. 818–833.
- [56] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. Et Al. (2015). « Going Deeper With Convolutions ».
- [57] Szegedy Et Coll., 2015. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rab Rabinovich, A. (2015). « Aller Plus Loin Avec Les Circonvolutions. Actes De La Conférence De L'IEEE Sur La Vision Par Ordinateur Et La Reconnaissance De Formes » (Pp. 1-9).
- [58] Simonyan, K. & Zisserman, A. (2014). « Very Deep Convolutional Networks For Large-Scale Image Recognition ». Arxiv Preprint Arxiv 1409.1556.
- [59] : En ligne : Aditya Chatterjee Platforme Open Genus valable sur :  
<https://lq.opengenus.org/evolution-of-cnn-architectures/>, [Accées Le 10 Juillet 2021].
- [60] M. Daoudi Et F. Z. Bekraoui, «Commande À Distance Des Appareils Électroniques Par

Vision, » Université Ahmed Draia, Adrar, 2016.

[61] Yun Jiang, Li Chen, Xiao Xiao, Hai Zhang. « Breast Cancer Histopathological Image Classification Using Convolutional Neural Networks With Small SE-Resnet Module (2019) ».

[62] Ning, F., Delhomme, D., Lecun, Y., Piano, F., Bottou, L. & Barbano, P. E. (2005). « Toward Automatic Phenotyping Of Developing Embryos From Videos ». IEEE Transactions On Image Processing, 14(9), 1360–1371.

[63] Ciresan, D., Giusti, A., Gambardella, L. M. & Schmidhuber, J. (2012). « Deep Neural Networks Segment Neuronal Membranes In Electron Microscopy Images. Advances In Neural Information Processing Systems, Pp. 2843–2851.

[64] Long, J., Shelhamer, E. & Darrell, T. (2015). « Fully Convolutional Networks For Semantic Segmentation. Proceedings Of the IEEE Conference On Computer Vision And Pattern Recognition », Pp. 3431–3440.

[65] Huang, F. J., Boureau, Y.-L., Lecun, Y. Et Al. (2007). « Unsupervised Learning Of Invariant Feature Hierarchies With Applications To Object Recognition. 2007 IEEE Conference On Computer Vision And Pattern Recognition », Pp. 1–8.

[66] Zeiler, M. D., Taylor, G. W., Fergus, R. Et Al. (2011). « Adaptive Deconvolutional Networks For Mid And High-Level Feature Learning ». ICCV, 1(2), 6.

[67] Badrinarayanan, V., Handa, A. & Cipolla, R. (2015). «Segnet A Deep Convolutional Encoder-Decoder Architecture For Robust Semantic Pixel-Wise Labelling». Arxiv Preprint Arxiv 1505.07293.

[68] Noh, H., Hong, S. & Han, B. (2015). « Learning Deconvolution Network For Semantic Segmentation. Proceedings Of The IEEE International Conference On Computer Vision», Pp. 1520–1528.

[69] Ronneberger, O., Fischer, P. & Brox, T. (2015). « U-Net Convolutional Networks For Biomedical Image Segmentation. International Conference On Medical Image Computing And Computer-Assisted Intervention», Pp. 234–241.

[70] Badrinarayanan, V., Kendall, A. & Cipolla, R. (2017). « Segnet A Deep Convolutional Encoderdecoder Architecture For Image Segmentation». IEEE Transactions On Pattern Analysis And Machine Intelligence», 39(12), 2481–2495.

[71] Yu, F. & Koltun, V. (2015). « Multi-Scale Context Aggregation By Dilated Convolutions ». Arxiv Preprint Arxiv 1511.07122.

[72] Krahenbuhl, P. & Koltun, V. (2011). « Efficient Inference In Fully Connected Crfs With Gaussian Edge Potentials. Advances In Neural Information Processing Systems», Pp. 109–117.

[73] Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K. & Yuille, A. L. (2018). « Deeplab Semantic Image Segmentation With Deep Convolutional Nets, Atrous Convolution, And



Fully Connected Crfs. IEEE Transactions On Pattern Analysis And Machine Intelligence», 40(4), 834–848.

[74] Chen, L.-C., Papandreou, G., Schroff, F. & Adam, H. (2017). « Rethinking Atrous Convolution For Semantic Image Segmentation ». Arxiv Preprint Arxiv 1706.05587.

[75] Zhao, H., Shi, J., Qi, X., Wang, X. & Jia, J. (2017). « Pyramid Scene Parsing Network. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition», Pp. 2881– 2890.

[76] Anibal Pedraza, Jaime Gallego, Samuel Lopez, Lucia Gonzalez, Gloria Bueno, Arvydas Laurinavicius. « Annual Conference On Medical Image Understanding And Analysis ».

[77] : En ligne : Source forge, valable : <https://Sourceforge.Net/Projects/Staruml/>, [Consulté Le 16 Aout 2020].

[78] : En ligne : OPENCV valable sur : <https://Opencv.Org/About/>, [Consulté Le 23 Aout 2020].

[79] : En ligne : cours informatique, valable sur : <https://cours-informatique-gratuit.fr/dictionnaire/microsoft-office-word/>, [Consulté Le 23 Aout 2020].

[80] : En ligne : plateforme officiel PYTHON [en ligne]. Valable sur : <https://www.python.org/doc/essays/blurb/>, [Consulté Le 23 Aout 2020].

[81] : En ligne : plateforme officielle SLICER [en ligne] valable sur : <https://www.slicer.org/>, [Consulté Le 23 Aout 2020].

[83] : En ligne : plateforme FLASK for you [en ligne]. Valable sur : <https://pymbook.readthedocs.io/en/latest/flask.html>, [Consulté Le 23 Aout 2020].

[84] : En ligne : plateforme Wikipédia [en ligne] valable sur : [https://en.wikipedia.org/wiki/Jinja\\_\(template\\_engine\)](https://en.wikipedia.org/wiki/Jinja_(template_engine)), [Consulté Le 23 Aout 2020].

[85] : En ligne : plateforme TECHTARGET [en Ligne]. Valable sur : <https://searchdatamanagement.techtarget.com/definition/MongoDB>, [Consulté Le 23 Aout 2020].

[86] : En ligne : plateforme journal du net [en ligne]. Valable sur : <https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1203255-html-hypertext-markup-langage-definition-traduction/>, [Consulté Le 23 Aout 2020].

[87] : En ligne : plateforme FUTURA TECH [en ligne] valable sur : <https://www.futura-sciences.com/tech/definitions/internet-css-4050/>, [Consulté Le 23 Aout 2020].

[88] : En ligne : plateforme TUTORIELUSPOINT [en ligne]. Valable sur : [https://www.tutorialspoint.com/javascript/javascript\\_overview.html](https://www.tutorialspoint.com/javascript/javascript_overview.html), [Consulté Le 23 Aout 2020].