



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

Université Larbi Tébessi - Tébessa

Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie  
Département : Mathématiques et Informatique



Mémoire de fin d'étude  
Pour l'obtention du diplôme de MASTER  
Domaine : Mathématiques et Informatique  
Filière : Informatique  
Option : Systèmes d'information

Thème

*Une méthode pour la segmentation des images  
pulmonaires pour le diagnostic de COVID'19*

Présenté Par :  
Hafiane Saloua

Devant le jury :

Mr. Zeggari Ahmed	MCB	Université Larbi Tébessi	Président
Mr. Souahi Med saleh	MCB	Université Larbi Tébessi	Examineur
Mr. Amroune Mohamed	MCA	Université Larbi Tébessi	Encadreur
Mr. Haouam Med Yacine	MCB	Université Larbi Tébessi	Co-Encadreur

Date de soutenance : 11 juillet 2021

## **Résumé**

Depuis décembre 2019, l'épidémie de la maladie à coronavirus (COVID-19) a causé de nombreux décès et touché tous les secteurs de la vie humaine.

Motivés par ce fait, un grand nombre de travaux de recherche ont été proposés et développés pour les premiers mois de 2020. Dans ce travail, nous nous concentrons d'abord sur la synthèse des travaux de recherche les plus récents liés aux applications d'apprentissage en profondeur du traitement d'images médicales COVID-19. Nous vérifions cela à partir de modèles d'apprentissage en profondeur pour la segmentation des régions infectées par la pneumonie dans Des tomodensitogrammes pour la détection du COVID-19.

Aujourd'hui, le traitement d'images joue un rôle important dans de nombreux domaines.

Dans le système de traitement d'images, le processus le plus important est la segmentation d'image.

**Mote clé:**COVID-19, apprentissage profond ,segmentation d'image , CT images, U-Net architecture

## **Abstract**

Since December 2019, the coronavirus disease (COVID-19) epidemic has caused numerous deaths and affected all sectors of human life.

Motivated by this fact, a large body of research work has been proposed and developed for the first months of 2020. In this work we focus first on the synthesis of the most recent research work related to learning applications in-depth COVID-19 medical image processing. We verify this from deep learning models for segmentation of pneumonia infected regions into CT scans for detection of COVID-19.

Today, image processing plays an important role in many fields. In image processing system, the most important process is segmentation image.

**Key word:** COVID-19, deep learning, image segmentation, CT images, U-Net architecture

## ملخص

منذ ديسمبر 2019 ، تسبب وباء فيروس كورونا (COVID-19) في وفيات عديدة وأثر على جميع قطاعات الحياة البشرية. بدافع من هذه الحقيقة ، تم اقتراح وتطوير مجموعة كبيرة من الأعمال البحثية للأشهر الأولى من عام 2020. في هذا العمل نركز أولاً على توليف أحدث الأعمال البحثية المتعلقة بتطبيقات التعلم المتعمق للصورة الطبية لـ COVID-19 يتم المعالجة. نتحقق من ذلك من نماذج التعلم العميق لتجزئة المناطق المصابة بالالتهاب الرئوي إلى فحوصات التصوير المقطعي المحوسب للكشف عن COVID-19. تلعب معالجة الصور اليوم دورًا مهمًا في العديد من المجالات. في نظام معالجة الصور ، فإن أهم عملية هي التجزئة صورة.

الكلمة المفتاحية: COVID-19 ، التعلم العميق ، تجزئة الصور ، صور التصوير المقطعي المحوسب ، هندسة-U

Net

# Remerciement

Au-dessus de tout, nous remercions Dieu Tous Puissant, pour nous avoir donné la force et la volonté d'accomplir ce modeste travail .

- Tout d'abord, je tiens particulièrement à remercier mon encadreur :Mr,*AmrouneMohamed*pour avoir encadré et dirigé ce travail.
- Mes remerciements s'adressent aussi a Mrs .*HaouamMed Yacine*pour son attention, son don d'écoute, sa tolérance et sa disponibilité, nous lui témoignons toute notre reconnaissance pour nous avoir guidé et prodigué des conseils sur le plan scientifique que sur le plan humain.
- Nous tenons à remercier les membres du jury : A Mr,*Zeggari Ahmed*. D'avoir accepté de présider ce jury.
- A Mrs ,*Souahi Med elsaleh*qui nous a honorés de bien vouloir examiner ce travail.
- Mes remerciements s'adressant aussi à tous ceux qui m'ont accompagné tout au long de mes études.
- A mes chers parents, de leur confiance, encouragement et de leur sacrifice durant toute ma vie je souhaite que ce travail soit le fruit de leurs efforts....

# Dédicace

je dédie ce modeste travail à :

- ❖ Mon chère Grand-père Lazher ( الله يرحمه ) et Mes chers parents qui m'ai offert leuramours et leur soutient et qui n'ont cessé de m'encourager et m'enseigner persévérancedurant toute les années d'études.
- ❖ Ma sœur : IMENE .
- ❖ Tous Mes camarades de la promotion 2021 système d'information , Et a tous les enseignants quiM'ai enseigné durant mes années d'études et notre groupe de ( HADJER. LEILA . SOUHAYLA . RIADH .YOSSRA . NAWAL . IKHLAS . HANANE .CHADIA . NADIA)
- ❖ Tous Ma famille et Mes cousins.

## Liste des abréviations

**CNN** : Les réseaux de neurones convolutifs

**CT** : tomographie

**FN** : False Negatives.

**FP** : False Positives.

**GoogLeNet** : ImageNet Large-Scale Visual Recognition Challenge

**IA** : intelligence artificielle

**ICTV** : Comité international de taxonomie virale

**OMS** : Organisation mondiale de la Santé

**PCR** : Polymerase Chain Reaction

**Res-net** : residual neural network

**Sars-CoV** : syndrome respiratoire aigu sévère

**TDM** : La tomodensitométrie

**TN** : True Negatives.

**TP** : True Positives.

**U-Net** : Network architecture

**VGG** : Visual Geometry Group

## Liste de figure

Figure 1.1: Test PCR. ....	7
Figure 1. 2: Radiographie de thorax : pneumopathie alvéolo- interstitielle bilatérale prédominant aux bases chez un COVID +. ....	9
Figure 1. 3:TDM : images de condensation avec verre dépoli, bilatérales, prédominant en périphérie dans un contexte de COVID + ....	10
Figure 1. 4:TDM : image de nodule excavé évoquant un abcès chez un malade COVID-19. ....	10
Figure 1. 5:Echographie thoracique : image du rideau avec atténuation des lignes A avec larges lignes B . ....	11
Figure 1. 6:Les signes et symptômes d'une infection par le covid-19. ....	12
Figure 1. 7:Appareil de respiration.....	12
Figure 1. 8:Appareil de fièvre.....	13
Figure 1. 9:différentes symptômes de covid 19 légères à grave.....	13
Figure 2. 1: Chaîne de segmentation d'image.....	16
Figure 2. 2: Extraction de caractéristiques (Niveau de gris). ....	17
Figure 2. 3: Agrégation itérative des blocs similaires au bloc 1.....	20
Figure 2. 4:Evolution du contour actif.....	22
Figure 2. 5:Les méthodes de segmentation par classification. ....	23
Figure 2. 6:Structure d'un neurone artificiel.....	23
Figure 2. 7:Architecture des réseaux de neurones convolutifs.....	24
Figure 2. 8:Les couche de CNN. ....	25
Figure 3. 1: Vue d'ensemble de modèle proposée.....	30
Figure 3. 2:U-Net architecteur.....	33
Figure 3. 3:Exemple Iou. ....	34
Figure 3. 4:image CT thoracique a)Entrée dans l'architecture U-Net ....	35
Figure 3. 5:image CT thoracique b)sortie la mask détectée par U-Net. ....	35
Figure 3. 6:precision de model ....	35
Figure 3. 7:: iou de model.....	36
Figure 3. 8:acc de model.....	36



## Table mat re

Introductin g�n�ral.....	1
Chapitre1 .....	3
Maladie de covid-19 .....	3
1. Introduction .....	4
2. D�finition .....	4
3. Structure .....	5
4. G�nome .....	5
5. Le diagnostic de l'infection par le Covid-19.....	5
5.1. Les tests mol�culaire par PCR.....	6
5.2. Les tests s�rologiques .....	7
6. Examen d'imagerie thoracique.....	8
6.1. Rayon X de thorax (Radiographie).....	8
6.2. La tomodensitom�trie (TDM) .....	9
6.3. L'�chographie .....	11
7. D�pistages du covid19 .....	11
8. Les sympt�mes.....	12
9. Conclusion.....	14
Chapitre2 : .....	15
1. Introduction .....	16
2. Chaine de traitement d'image .....	16
3. Segmentation d'image:.....	17
3.1. La segmentation.....	17
3.2. D�finition de la segmentation d'image.....	18
3.3. Objectifs de la segmentation .....	18
4. Les m�thodes de segmentation d'image.....	19
4.1. Segmentation bas�e r�gion .....	19
4.1.1. Croissance de r�gion (growing region) .....	19
4.1.2. La m�thode split and merge.....	19
4.2. La segmentation bas�e seuillage.....	20
4.3. Segmentation bas�e contour .....	21
4.4. Segmentation par classification :.....	22
4.5. Les m�thodes bas�es sur le Deep Learning .....	24

4.5.1. Les réseaux de neurones convolutifs (CNN).....	24
5. Aperçu superficiel de quelques travaux pour la segmentation d'image.....	27
6. Conclusion.....	28
Chapitre 3 : .....	29
Une Méthode basée Deep Learning pour la segmentation des images CT du CORONA VIRUS .....	29
1. Introduction .....	30
2. Architecture de modèle proposée.....	30
3. Ressources utilisée .....	31
3.1. Dataset .....	31
3.3. Prétraitement des données (Data pre-processing) .....	31
4. Présentation des outils utilisés .....	31
5. La méthode U-Net(Convolutional Networks).....	32
6. Métrique évaluation.....	34
.7 Resultat et discussion .....	35
8. Conclusion.....	36
Conclusion Général .....	38

## Introduction générale

Le virus CORONA est l'un des virus qui infecte le système respiratoire de l'être humain, représentant 15 % des virus de la grippe qui infectent les humains. Les informations sur COVID-19 continuent d'évoluer à mesure que nous partageons diverses expériences à l'échelle mondiale. Cet aperçu est basé sur des directives et des connaissances développées et partagées par toute la communauté scientifique. Parmi cette équipe nous trouvons les informaticiens qui essaient de donner un coup de main en utilisant des avancées qu'offre l'intelligence artificielle.

Dans cette optique, le développement rapide des technologies d'imagerie médicale est entrain de révolutionner la médecine. L'imagerie médicale permet aux scientifiques et aux médecins d'avoir des informations vitales en examinant le corps humain.

L'imagerie médicale joue un rôle de plus en plus important dans le diagnostic et le traitement de la maladie. Le traitement d'images médicales doit être rapide et il doit aussi déceler le plus tôt possible une anomalie surtout dans le cas de covid19 .

Dans le même contexte se situe notre travail qui portera sur la segmentation d' images CT scan dans l'objectif d'extraire les zones suspectes pour faciliter le diagnostic de ces images ultérieurement : La question n'est pas de se substituer au médecin, mais de lui proposer des outils performants qui l'aident dans son travail d'analyse des clichés pulmonaires du COVID19 .

Ce manuscrit est composé d'une introduction générale et trois chapitres. Le premier chapitre introduit les concepts relatifs au contexte médical du COVID19 , il présente la définition et la structure, les tests moléculaire par PCR ,Examen d'imagerie thoracique et leurs symptômes en passant par le dépistage du covid19 .

Dans le deuxième chapitre, présente une vue détaillée sur la segmentation définition, leur objectif ,les différent approche classique et approche basée DeepLearning ainsi que la présentation d'état de l'art des techniques utilisées pour le diagnostic du COIVID19.

Le troisième chapitre présente notre approche. Il comprend deux parties : une partie théorique qui correspond à la démonstration des méthodes utilisées, et une partie pratique regroupant des exemples d'utilisation de notre approche.

# **Chapitre 1**

## **Maladie de covid-19**

## 1. Introduction

Le terme “imagerie médicale” remplace aujourd’hui les appellations “radiologie” ou “radiodiagnostic” .

L’imagerie médicale ne cesse d’évoluer et de se perfectionner en utilisant des technologies novatrices de plus en plus précises et performantes. Il est désormais possible, non seulement d’observer un organe, mais aussi de le voir fonctionner, grâce à des images fixes ou animées. L’imagerie médicale est de plus en plus utilisée pour le diagnostic, en complément d’un examen clinique et d’autres investigations, comme des examens biologiques ou des tests neuropsychologiques.

## 2. Définition

Le nouveau coronavirus (2019-nCoV), appelé encore le Sars-CoV-2 par le Comité international de taxonomie virale (ICTV). [1], appartient à la famille Coronaviridae (sous-type Coronavirinae et genre  $\beta$ etacoronavirus). Il a été transmis à l’homme probablement par le pangolin, sur un marché de fruits de mer à Wuhan, dans la province du Hubei, en Chine, en décembre 2019, [2]. La découverte d’une pneumonie d’étiologie inconnue a poussé les chercheurs chinois à isoler rapidement l’agent pathogène en janvier 2020. La rapidité de la transmission interhumaine a causé une pandémie.

L’OMS a nommé, le 11 février, la maladie respiratoire provoquée par le Sars-CoV-2 : le Covid-19. Elle est considérée comme urgence de santé publique à portée internationale. Au Maroc, jusqu’au 23 mai 2020, 7 429 cas sont isolés avec 4 686 guérisons et 198 décès.

La vitesse de propagation du Sars-CoV-2 a conduit les scientifiques partout dans le monde à mener de nombreuses recherches pour mieux connaître et affronter ce virus redoutable, qualifié par l’OMS d’« ennemi de l’humanité ». Cet article résume les connaissances actuelles virologique, épidémiologique et diagnostique sur le Covid-19. Comme l’évolution des connaissances sur ce nouveau virus est permanente, les lecteurs sont invités à se mettre à jour régulièrement

### 3. Structure

Virus sphérique, enveloppé de 60-220 nm, comprend de l'extérieur vers l'intérieur, la glycoprotéine Spike (S) (donne l'aspect en couronne au virus en microscopie électronique), l'enveloppe, la membrane et la nucléocapside elle-même, icosaédrique à symétrie cubique. Cette dernière contient une molécule de génome viral : de l'acide ribonucléique (ARN) monocaténaire, non segmenté et positif (29 881 paires de bases). [3]

### 4. Génome

Le génome des CoV comporte un nombre variable de cadres de lecture ouverts (ORF). Les deux tiers de l'ARN viral sont situés principalement dans le premier ORF (ORF1a/b), traduit deux polyprotéines, pp1a et pp1b, et code pour 16 protéines non structurales (NSP), alors que les ORF restants codent pour des protéines de structure et des protéines accessoires. Le reste du génome du virus code pour quatre protéines essentielles de structure, dont la glycoprotéine (S), la protéine de l'enveloppe (E), la protéine matricielle (M) et la protéine nucléocapside (N), ainsi que plusieurs protéines accessoires, qui interfèrent avec la réponse immunitaire de l'hôte.[3].

L'étude de Wu *et al.* a montré une similitude génomique et phylogénétique avec le Sars-CoV, en particulier dans le gène de la glycoprotéine S .[4]. J. Zhang *et al.* ont analysé le génotype de différents patients atteints du Covid-19 et ils ont constaté des modifications rares et spontanées du génome viral.[5]. L'étude de Tang *et al.* a analysé 103 génomes de patients infectés par le Covid-19 et a permis d'identifier deux souches de Sar-CoV-2 : la souche L et la souche S. La souche L est plus agressive et contagieuse.[6].

### 5. Le diagnostic de l'infection par le Covid-19

En l'absence de médicaments thérapeutiques ou de nombre limité de doses de vaccins contre le COVID-19, il est essentiel de détecter la maladie à un stade précoce et d'isoler immédiatement la personne infectée de la population saine.

Le diagnostic de COVID-19 repose sur un ensemble de symptômes cliniques ainsi que sur des

examens biologiques (tests d'amplification des acides nucléiques) et d'imagerie.

Le diagnostic biologique utilise les échantillons sanguins et respiratoires, notamment de

gorge, oropharyngés et nasaux, et de salive sur des patients suspects comme échantillons cliniques pour la détection du Covid-19. Cependant, l'obtention des résultats demande plusieurs heures, et seuls certains laboratoires disposent de ce test. En plus, la qualité de la réalisation des prélèvements (écouvillon nasal profond) et la durée de transport vers les laboratoires sont des points essentiels pour éviter les faux négatifs.

Le scanner thoracique s'est rapidement imposé comme un outil diagnostique intéressant, compte tenu de la présentation souvent assez caractéristique des lésions de COVID-19.[7].

### **5.1.Les tests moléculaire par PCR**

Il existe de nombreux tests moléculaires de détection du SARS-CoV-2 qui sont bien caractérisés et qui démontrent une sensibilité et une spécificité élevées. Cela signifie que si les tests sont correctement effectués et à condition que les normes en matière d'échantillonnage, de transport et de capacités des laboratoires soient respectées, le risque de résultats faussement négatifs et faussement positifs des TAAN est faible. Les exigences relatives à l'infrastructure et à la sécurité biologique pour les tests moléculaires en laboratoire sont strictes [8]. Les tests d'amplification des acides nucléiques (TAAN), comme la RT-PCR en temps réel, sont le type de test recommandé pour confirmer une infection par le SARS-CoV-2 (8) .permis les techenique du RT-PCR :

#### **a. Prélèvements**

Actuellement, le diagnostic spécifique de Covid-19 est réalisé par une RT-PCR spécifique sur un écouvillonnage nasopharyngé. Le résultat peut être obtenu généralement en quatre heures.

Les prélèvements à réaliser pour le diagnostic initial de Covid-19 sont les suivants : nasopharyngé et un prélèvement des voies respiratoires basses (crachats, LBA, ATB) en cas d'atteinte parenchymateuse et le sang [9].





Figure 1.1: Test PCR.

### **b. Acheminement**

Le clinicien doit informer le laboratoire de la suspicion d'infection Covid-19. Les échantillons respiratoires sont adressés au laboratoire par un transporteur en utilisant un conditionnement de catégorie B (norme UN 3373)/triple emballage (tube – contenant rigide à visser – Biotainer rigide UN 3373). Ne pas utiliser de pneumatique.[9]

## **5.2.Les tests sérologiques**

Les tests sérologiques permettent la détection des anticorps (Ac) spécifiques (immunoglobulines : Ig) produits par l'organisme et dirigés contre le Sars-CoV-2. Ces tests sont réalisés sur des prélèvements de sang et pourraient utiliser pour identifier les patients ayant développé une immunité vis-à-vis du Sars-CoV-2 qu'ils aient été symptomatiques ou pas. Les tests sérologiques pourraient identifier dans certaines circonstances les patients étant ou ayant été infectés par le Sars-CoV-2, connaître le statut sérologique de personnes exposées (professionnels de santé par exemple). Enfin, ces tests pourraient également avoir une utilité dans le recueil des données épidémiologiques liées au Covid-19 (patients réellement infectés, taux de mortalité...). Toutefois, la pertinence du recours à ces tests en pratique clinique dépend de la disponibilité préalable de connaissances physiopathologiques, techniques et cliniques permettant leur évaluation et leur validation [10].

Guo *et al.* ont montré, que les IgA et IgM anti-protéine de la nucléocapside sont détectés dans un délai médian de cinq jours après l'apparition des premiers symptômes dans 85,4 % et 92,7 % des cas respectivement. Les IgG sont détectées dans un délai médian de quatorze jours et dans 77,9 % des cas. L'association RT-PCR et test Elisa IgM détectent 98,7 % des cas [11].

Une seconde étude portant sur 173 patients a montré un délai plus long pour la détection des IgM antiprotéine M, avec un délai médian de douze jours [12] .


### **a. Tests antigéniques**

Les tests antigéniques détectent les protéines spécifiques du Sars-CoV-2. Ces tests peuvent être réalisés sur des prélèvements nasopharyngés, des prélèvements des voies respiratoires basses. Comme les tests de RT-PCR, ils assurent le diagnostic précoce de la maladie dès la phase aiguë. Toutefois, compte tenu de leurs faibles performances notamment en cas de charge virale basse, ces tests antigéniques ne sont à ce jour pas recommandés en usage clinique dans le cadre du Covid-19, comme l'a souligné l'OMS dans sa position du 8 avril 2020.[10].

## **6. Examen d'imagerie thoracique**

### **6.1. Rayon X de thorax (Radiographie)**

Moins sensible effectuée par défaut et n'ayant de valeur que si elle montre des anomalies (Fig1.1).



**Figure 1. 2: Radiographie de thorax : pneumopathie alvéolo- interstitielle bilatérale prédominant aux bases chez un COVID +.**

## **6.2.La tomodensitométrie (TDM)**

La TDM sans injection en coupes fines est l'examen de référence : images en verre dépoli, bilatérales, prédominant en périphérie dans les lobes inférieurs avec possible pleurésie et lymphadénopathies ; syndrome interstitiel (**Fig1.2 etFig1. 3**) .

- pas d'indication à des fins de dépistage chez des patients sans signes de gravité et sans comorbidités ;
- indiquée chez les patients ayant un diagnostic suspecté ou confirmé et des signes de gravité clinique (dyspnée, désaturation...) initiaux ou secondaires relevant d'une prise en charge hospitalière.[13,14] .




Figure 1. 3:TDM : images de condensation avec verre dépoli, bilatérales, prédominant en périphérie dans un contexte de COVID +



Figure 1. 4:TDM : image de nodule excavé évoquant un abcès chez un malade COVID-19.

### 6.3.L'échographie

L'échographie est une technique d'exploration de l'intérieur du corps basée sur les ultrasons. Une sonde envoie un faisceau d'ultrasons dans la zone du corps à explorer. Selon la nature des tissus, ces ondes sonores sont réfléchies avec plus ou moins de puissance. Le traitement de ces échos permet une visualisation des organes observés[15].



Figure 1. 5: Echographie thoracique : image du rideau avec atténuation des lignes A avec larges lignes B .

## 7. Dépistages du covid19

La tomographie calculée (CT) est un test qui fournit une fenêtre pathophysiologique qui pourrait éclairer les étapes de la maladie et de l'évolution . [16 .17.18]. tandis que les défis se poursuivent avec un diagnostic rapide de COVID 19 , les radiologues de première ligne signalent un modèle d'infection quelque peu caractéristique des caractéristiques typiques , notamment des opacités de verre au sol dans la périphérie pulmonaire , des opacités arrondies , des navires intra -infiltrats élargis , et plus tard plus de consolidations qui sont un signe de progression d'une maladie grave . bien que le CT et le RT-PCR sont le plus souvent concordants, CT peut également détecter le covid-19 précoce chez les patients présentant un test négatif RT-PCR [19] .chez des patients sans symptômes ou avant que des symptômes ne se développent ou après les symptômes résolvant le [19.20].

## 8. Les symptômes

Peuvent varier de légers à graves, et se manifestent 2 à 14 jours après l'exposition au virus qui est à l'origine du **COVID-19**.

Consultez immédiatement un médecin si une personne présente des signes avant-coureurs de COVID-19.

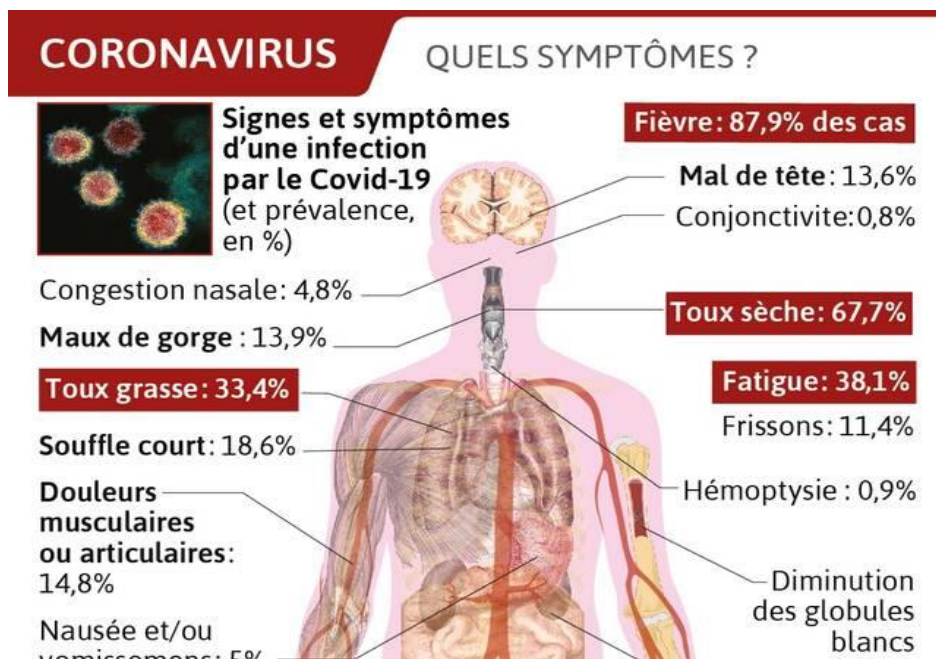


Figure 1. 6:Les signes et symptômes d'une infection par le covid-19.

- Difficultés à respirer.



Figure 1. 7:Appareil de respertoire.

- Douleur ou pression persistante au niveau du torse.
- Nouvelle confusion.
- Fièvre



Figure 1. 8:Appareil de fièvre.

- Incapacité à se réveiller ou à rester éveillé(e).
- Peau, lèvres ou lits d’ongles pâles, gris ou bleuâtres, selon le teint de la peau [21].



Figure 1. 9:différentes symptômes de covid 19 légères à grave.

## 9. Conclusion

Dans ce chapitre ont été abordées des notions de généralité en rapport avec le covid19. Après avoir présenté de façon concise les tests moléculaires et les tests sérologiques , et leurs symptômes en passant par le dépistage du covid 19 et leur examen d'imagerie thoracique, de L'objectif qui sous-tend la présentation de ces éléments, c'est de mettre en lumière les difficultés rencontrées par les radiologues dans le détectage de covid 19 . Notre travail va s'orienter vers la segmentation d'image de covid 19 en utilisant les méthodes de ségmentation qui est le sujet de notre suivant chapitre.



# **Chapitre2 :**

## Techniques de segmentation d'images

## 1. Introduction

En analyse d'images, la segmentation est une étape essentielle des traitements de haut niveau tels que la classification, la détection ou l'extraction d'objets. Elle consiste à décomposer une image en régions homogènes. Les trois principales approches sont l'approche région, l'approche par classification de pixels et l'approche contour.

Dans le domaine de médecine, la segmentation d'images permet d'extraire des structures anatomiques spécifiques et de localiser certaines pathologies au sein d'une séquence d'images numériques ce qui apporte une amélioration très intéressante au processus de diagnostic médical.

Actuellement, Il n'y a pas d'algorithmes de segmentation efficaces sur tout type d'images. De nombreuses méthodes ont été proposées en adaptant des méthodes existantes pour enlever certaines limitations pour certains domaines d'applications. Dans ce chapitre, nous allons présenter quelques méthodes de segmentation.

## 2. Chaîne de traitement d'image

Le processus de traitement d'image se décompose en plusieurs étapes [22] :

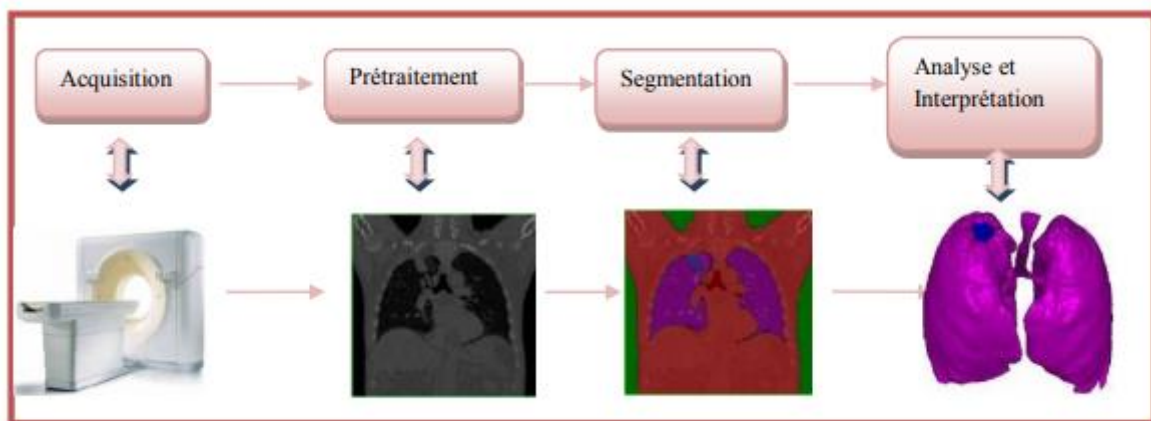


Figure 2. 1: Chaîne de segmentation d'image

- **Acquisition d'une scène (image)** : permet de discrétiser l'image réelle afin d'être traitée par l'ordinateur.
- **Prétraitement** : permet d'obtenir l'image la plus nette que possible.

- **Segmentation** : permet l'extraction des indices pertinents présents dans l'image (région, contour, ...). Dans ce travail, nous avons opté pour la segmentation par approche classification qui se décompose à son tour en trois étapes :

- ❖ **Extraction de caractéristiques** : l'image est représentée dans l'algorithme de segmentation par son vecteur de caractéristiques, nommé souvent vecteur d'attributs. Ce vecteur, selon le sujet traité, peut être formé par les niveaux de gris de l'image, des mesures locales (moyenne, variance, ....), coordonnées spatiales des pixels ... etc.




Figure 2. 2: Extraction de caractéristiques (Niveau de gris).

- ❖ **Classification** : (ou clustering) est le processus de regroupement d'objets similaires en une classe (cluster) unique, et les objets dissimilaires en des classes différents. Ceci selon un critère de similarité donné.

- ❖ **Post-traitement** : visualisation, stockage, .... (dans le cas de CNN, la fonction d'appartenance obtenue est utilisée pour afficher l'image et ses différentes classes).

- **Interprétation des résultats et prise de décisions.**

### 3. Segmentation d'image:

#### 3.1.La segmentation

La segmentation selon le dictionnaire Larousse, est la division d'une unité anatomique en plusieurs éléments. En traitement d'image, la segmentation est un processus visant à décomposer la séquence d'images en un ensemble de régions .ou classes homogènes au sens d'un ou plusieurs critères

### 3.2.Définition de la segmentation d'image

La segmentation est un traitement de bas-niveau qui consiste à décomposer complètement ou partiellement une image en régions selon un critère déterminée (couleur, texture, niveau de gris,...). Ces régions possèdent une corrélation forte avec les objets d'intérêt à détecter dans l'image [23]. Elle permet ensuite de visualiser et de quantifier ces objets. La définition formelle de la segmentation comme traitement de bas niveau date de l'année 1974 [24] et propose de partitionner l'image  $I$  en un ensemble  $R_i$  disjoints et connexes appelés régions tels que :

- $\forall_i R_i \neq 0$
- $R_i$  est connexe
- $p(R_i)$  vrai  $\forall_i$
- $p(R_i \cup R_j)$  faux
- $\forall_{i,j} R_i \cap R_j = 0$
- $I = \bigcup_i R_i$

La qualité de la segmentation, c'est à dire, la précision de la localisation et la non confusion des régions, a un impact direct sur les performances de l'application. Malgré les nombreuses recherches qui ont eu lieu dans le passé sur les méthodes de segmentation, le problème de la segmentation reste toujours mal posé, car on ne sait jamais dire quelle est la segmentation idéale.

### 3.3.Objectifs de la segmentation

- Fournir des régions homogènes (selon un critère donné)
- Localiser de manière précise les contours des régions.
- L'étude et l'interprétation des structures anatomiques.
- Réduction de bruit. [25]

La segmentation est basée sur [26]:

- Un ensemble d'entités.
- un ensemble d'attributs caractérisant ces entités.
- des relations topologiques entre ces entités

- des attributs relationnels.

#### **4. Les méthodes de segmentation d'image**

Généralement, les méthodes de segmentation sont regroupées en quatre approches, chacune ayant des avantages et ses domaines d'application et elles sont par fois complémentaires, ces approches sont :

1. Segmentation basée sur les contours (en anglais : edge-based segmentation)
2. Segmentation basée sur les régions (en anglais : régions-based segmentation).
3. Segmentation basée sur le seuillage
4. Segmentation en utilisant la classification.

##### **4.1.Segmentation basée région**

Les méthodes de l'approche région cherchent à regrouper directement des pixels ayant une propriété commune. L'ensemble des regroupements de pixels définit à la fin une segmentation de l'image [27].

###### **4.1.1. Croissance de région (growing region)**

La croissance s'effectue à partir des pixels initiaux appelés "germes". Ces germes peuvent être sélectionnés de façon aléatoire ou automatique. Les pixels connexes à un germe respectant un certain critère de similarité (niveau de gris, texture...) sont intégrés dans le germe. Les pixels non intégrés aux régions peuvent générer eux-mêmes de nouvelles régions ou être comme même assimilés à la région la plus proche. La croissance de région s'interrompt lorsque les pixels adjacents aux régions sont affectés. [28].

###### **4.1.2. La méthode split and merge**

Cette méthode a été présentée pour la première fois en 1974 par Pavlidis et Horowitz. Son principe est de combiner les deux méthodes division et fusion de régions de la manière suivante : Une première étape de division donne comme résultat une image divisée en plusieurs régions. Par la suite, une étape de fusion intervient afin de corriger les résultats

obtenue par la première étape, en regroupant les régions similaires. Ce procédé est répété jusqu'à l'obtention d'une bonne segmentation [29].




Figure 2. 3: Agrégation itérative des blocs similaires au bloc 1.

## 4.2.La segmentation basée seuillage

Le seuillage est une méthode simple et très populaire pour le traitement des images. Le seuillage a pour objectif de segmenter une image en plusieurs classes en utilisant que l'histogramme. Il existe de nombreuses méthodes de seuillage d'un histogramme, la plupart de ces méthodes s'appliquent correctement si l'histogramme contient réellement des pics séparés.

### a- Seuillage global

Le principe consiste à regrouper les pixels selon leurs attributs (intensité, contraste...etc) sans tenir compte de leur localisation au sein de l'image. Cela permet de construire des classes de pixels, les pixels adjacents appartenant à une même classe forment alors des régions. L'objectif consiste à affecter à chaque pixel de l'image une étiquette  $e_i$  indiquant la classe  $i$  (régions) la plus proche (mesure de distance entre le pixel et le centre de gravité de la classe) [30].

### b- Seuillage local :

Dans cette technique de seuillage, le seuil de tous les points de l'image est en fonction de l'illumination dans le voisinage [31]. Donc l'image est partitionnée en différentes sous régions et un seuil est déterminé pour chacune de ces sous régions. Pour les zones dans lesquelles la définition d'un seuil n'est possible, le seuil est déterminé par interpolation à partir des zones voisines

### 4.3. Segmentation basée contour

Un contour est un ensemble de points d'une image numérique qui correspond à un changement brutal de l'intensité lumineuse [32].

Dans l'approche "contour", on considère que les primitives à extraire sont les lignes de contrastes séparant des régions de niveaux de gris différents et relativement homogènes, ou bien des régions de texture différentes. En pratique, il s'agit de reconnaître les zones de transition et de localiser au mieux la frontière entre les régions. Parmi les méthodes de cette catégorie :

**Contours actifs :** Les contours actifs (snake) sont définis par une courbe paramétrique pouvant être fermée ou non. Un snake consiste à placer aux alentours de la forme à détecter une ligne initiale de contour. Cette ligne va se déformer progressivement selon l'action de plusieurs forces qui vont la tirer ou la pousser vers la forme.

Ces forces sont représentées par trois énergies associées au snake [33] :

- **Une énergie propre :** due uniquement à la forme du contour, dite **interne**.
- **Une énergie potentielle :** imposée par l'image dite énergie **externe**.  
C'est elle qui va attirer la ligne du snake vers les contours réels présents sur l'image
- **Une énergie de contexte :** qui exprime certaines contraintes supplémentaires qui peuvent être imposées par l'utilisateur vu le snake qu'il veut obtenir.

Le contour actif peut être décrit par une courbe  $C$ , fonction du temps  $t$  et de l'abscisse curvilignes par la formule suivante :

$$C = \{V(s, t) = (x(s, t), y(s, t)) / s \in [a, b] \text{ et } t \in [0, t]\}$$

Donc, le contour actif est formé d'une série de points mobiles et répartis sur une courbe en deux dimensions. La courbe est placée dans la zone d'intérêt de l'image ou autour d'un objet. Plusieurs équations décrivent son évolution : la courbe se déplace et épouse lentement les contours des objets en fonction de divers paramètres comme l'élasticité, la tolérance au bruit, etc.

Cette dynamique est basée sur la notion d'énergies interne et externe, le but étant de minimiser l'énergie totale présente le long de la courbe. Des contraintes permettent de conserver une courbe lisse avec des points équidistants tout en laissant un certain champ libre pour les déformations [34].




Figure 2. 4:Evolution du contour actif.

#### 4.4.Segmentation par classification :

Les méthodes de segmentation d'images par classification sont issues du domaine de classification des données multidimensionnelles. Elles définissent une partition de l'image en un ensemble de classes tel que chaque classe rassemble des pixels ayant des vecteurs de caractéristiques souvent réduit au niveau de gris aussi similaire que possible et que les classes soient aussi distinctes les unes des autres. Généralement, ces méthodes de segmentation ne prennent pas en compte la disposition spatiale des pixels et ne considèrent que le vecteur de caractéristiques utilisé. Elles identifient des classes de pixels présentes dans l'image et affectent à chaque pixel une étiquette indiquant la classe à laquelle il appartient. Ainsi, les pixels appartenant à une classe peuvent former plusieurs régions non adjacentes dans l'image mais partagent les mêmes propriétés statistiques. Une segmentation en régions n'est obtenue qu'après analyse de la connexité des pixels dans l'image étiquetée [35].

Généralement les résultats des méthodes de classification sont plus ou moins différents, la classification peut être supervisée ou non supervisée.



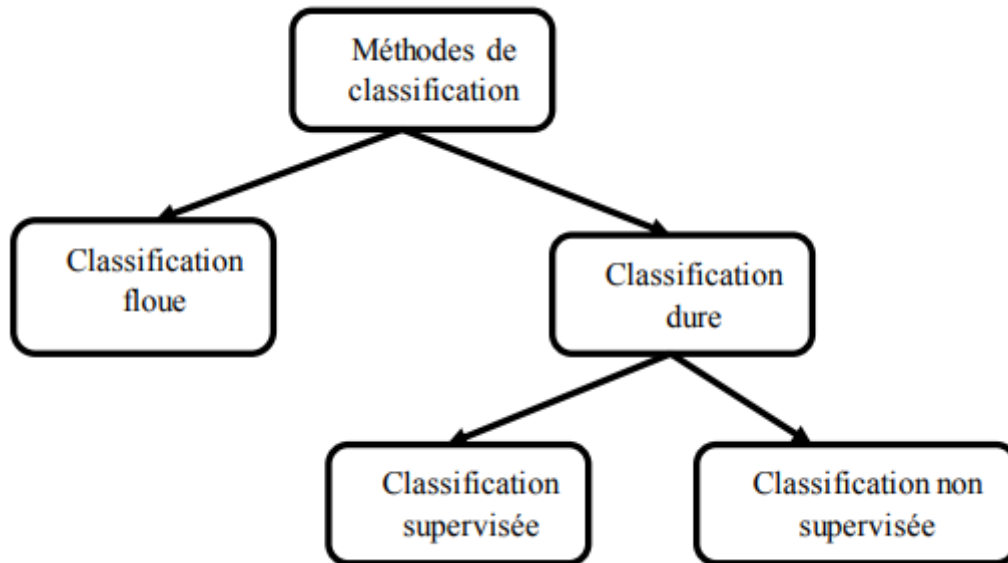


Figure 2. 5:Les méthodes de segmentation par classification.

### a. Méthodes supervisées

Les méthodes de classification supervisées supposent la connaissance a priori de l'appartenance de chaque échantillon de l'ensemble d'apprentissage à une classe donnée, ce qui revient à supposer une connaissance a priori sur l'image à segmenter [36].

L'une des méthodes les plus utilisées dans la classification supervisée est:

**Les réseaux de neurones :** Un "neurone formel" est une fonction algébrique non linéaire et bornée, dont la valeur dépend de paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées "entrées" du neurone et la valeur de la fonction est appelée sa "sortie". La période d'apprentissage consiste à calculer les différents coefficients, de sorte à ce que les sorties du réseau soient égales aux valeurs souhaitées (à un seuil d'erreur près) pour les exemples utilisés [24].

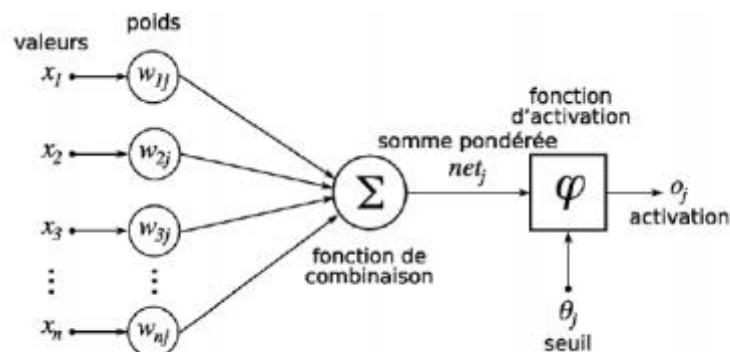


Figure 2. 6:Structure d'un neurone artificiel.

## b. Méthodes non supervisées (Automatiques)

La méthode de classification non supervisée a pour but de trouver des partitions d'un ensemble d'individus en fonction de critères de proximité de leurs vecteurs d'attributs dans l'espace de représentation. Elles sont utilisées pour effectuer une classification en aveugle et ainsi pour réaliser une segmentation sans connaissances a priori sur l'image. Il est par conséquent nécessaire de prendre quelques précautions. La mesure de proximité est calculée sur tous les attributs, il n'y a donc pas de réduction de l'espace de représentation. Comme il n'y a pas d'exemples d'apprentissage, si certains attributs utilisés sont non représentatifs des classes recherchées, le résultat pourra être médiocre [37].

## 4.5. Les méthodes basées sur le Deep Learning

### 4.5.1. Les réseaux de neurones convolutifs (CNN)

D'après les travaux de *M. Zeiler et R. Fergus* [38], les réseaux de neurones convolutifs « *CNN* » sont des types spécifiques de réseaux de neurones artificiels qui utilisent des perceptrons et un algorithme d'unité d'apprentissage automatique pour l'apprentissage supervisé, permettant d'analyser des données. Les CNN s'appliquent beaucoup plus au traitement d'images, aussi au traitement du langage naturel « *NLP* » et à d'autres types de tâches cognitives. Comme d'autres types de réseaux de neurones artificiels, un réseau de neurones convolutionnel comporte une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées (voir figure 2.). Certaines de ces couches sont convolutionnelles et utilisent un modèle mathématique et algébrique pour transmettre les résultats aux couches successives.

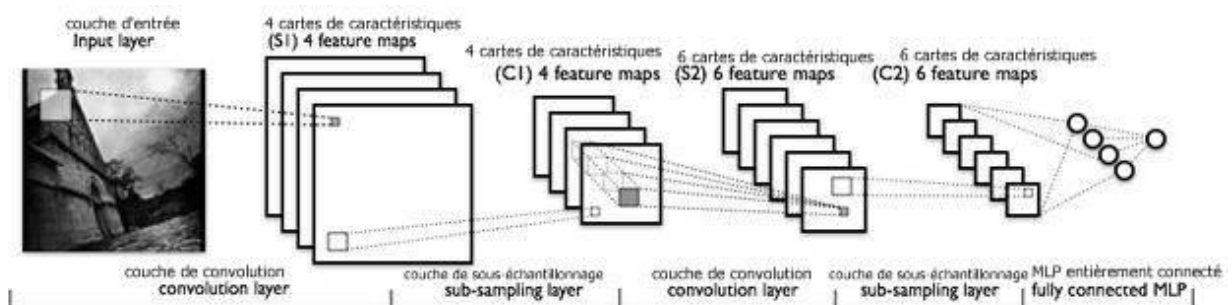


Figure 2. 7: Architecture des réseaux de neurones convolutifs.

Les réseaux « CNN » sont des exemples typiques de la technique d'apprentissage profond, où un modèle plus sophistiqué accélère l'évolution de l'intelligence artificielle en proposant des systèmes simulant différents types d'activités biologiques du cerveau humain. Généralement les réseaux « CNN » sont composés de quatre principales couches :

- La couche de convolution « *CONV* » qui traite les données d'entrées ou les résultats des couches intermédiaires ou cachées.
- La couche de *Pooling* « *POOL* », qui permet de compresser l'information en réduisant la taille de l'image intermédiaire.
- La couche d'activation, c'est des fonctions de rectification linéaire souvent appelée par «*ReLU*» qui permet la mise à jour des paramètres de la couche actuelle ainsi que les couches précédentes.
- La couche entièrement connectée « *Fully Connected* », qui est une couche de type perceptron.




Figure 2. 8:Les couche de CNN.

Les réseaux de neurones convolutifs (CNN) ont connu un énorme succès dans de nombreux domaines de la vision par ordinateur et de l'analyse d'images médicales.

Il existe plusieurs architectures dans le domaine des réseaux convolutifs qui ont un nom. Les plus courants sont :

#### a. AlexNet

Le premier travail qui a popularisé les réseaux convolutifs en vision par ordinateur est AlexNet, développé par Alex Krizhevsky, Ilya Sutskever et Geoff Hinton. AlexNet a été soumis au défi ImageNet LSVRC en 2012 et a largement surpassé le deuxième finaliste. Le réseau avait une architecture très similaire à LeNet, mais était plus profond, plus grand et comportait des couches convolutionnelles empilées les unes sur les autres (auparavant, il était courant de n'avoir qu'une seule couche CONV toujours immédiatement suivie d'une couche POOL).

### **b. GoogLeNet**

Le gagnant de l'ILSVRC 2014 « ImageNet Large-Scale Visual Recognition Challenge » était un réseau convolutif de Szegedy et al. de Google. leur principale contribution a été le développement d'un Inception Module qui a considérablement réduit le nombre de paramètres dans le réseau (4M, comparé à AlexNet avec 60M). De plus, utilisant la mise en commun moyenne au lieu des couches entièrement connectées en haut du ConvNet, éliminant une grande quantité de paramètres qui ne semblent pas avoir beaucoup d'importance. Il existe également plusieurs versions de suivi de GoogLeNet, la plus récente Inception-v4 [39].

### **c. VGGNet**

VGGNet est inventé par VGG (Visual Geometry Group) de l'Université d'Oxford, bien qu'il soit le finaliste de l'ILSVRC 2014. Sa principale contribution a été de montrer que la profondeur du réseau est un élément critique pour de bonnes performances. Leur meilleur réseau final contient 16 couches CONV / FC et, de manière attrayante, présente une architecture extrêmement homogène qui n'effectue que des convolutions 3x3 et une mise en commun 2x2 du début à la fin. Un inconvénient du VGGNet est qu'il est plus coûteux à évaluer et utilise beaucoup plus de mémoire et de paramètres (140M). La plupart de ces paramètres se trouvent dans la première couche entièrement connectée, et il a été constaté depuis que ces couches FC peuvent être supprimées sans dégradation des performances, ce qui réduit considérablement le nombre de paramètres nécessaires[39].

### **d. ResNet**

Residual Network développé par Kaiming He et al. a été le gagnant de l'ILSVRC 2015. Il comporte des connexions de saut « skip connections » spéciales et une utilisation intensive de la normalisation par lots « batch normalization ». L'architecture manque également de couches entièrement connectées à la fin du réseau [39].

## 5. Aperçu superficiel de quelques travaux pour la segmentation d'image

**X. Wang et al. [38]** ont proposé un CNN 3D profond (DeCoVNet) pour détecter le COVID-19 à partir de CT-scans. Le masque pulmonaire 3D a été généré par un UNet pré-entraîné.

Ensuite, la région pulmonaire 3D segmentée a été introduite dans un réseau de neurones profond 3D pour prédire la probabilité d'infection par le COVID-19. 499 CT-scans ont été utilisés pour l'entraînement et 131 CT-scans ont été utilisés pour le test.

**L. Huang et al. [40]** ont développé un modèle d'apprentissage profond, le réseau de neurones de détection du COVID-19 (COVNet), pour extraire les caractéristiques visuelles des CT-scans volumétriques du thorax pour la détection du COVID-19. La région pulmonaire est extraite en tant que région d'intérêt (ROI) en utilisant une méthode de segmentation basée sur U-net. Par la suite, la région pulmonaire extraite est prétraitée, puis transmise au réseau neuronal de détection COVID-19 proposé (COVNet) pour les prédictions.

**Jin et al. [41]** ont proposé un pipeline en deux étapes pour le dépistage du COVID-19 dans les images CT, dans lequel la région pulmonaire entière est d'abord détectée par une technique de segmentation efficace basé sur UNet++. Le modèle de segmentation a été entraîné sur 732 cas dont 704 contenaient une inflammation ou des tumeurs. Le modèle 3D U-Net++ utilisé a donné un coefficient Dice égal à 0,754.

**Shan et al. [42]** ont utilisé le réseau de neurones «VBNet» pour segmenter les régions d'infection COVID-19 dans des CT-scans. Le système est entraîné à l'aide de 249 patients COVID-19 et validé à l'aide de 300 nouveaux patients COVID-19. Le système proposé a donné un coefficient de similarité Dice de 91,6%  $\pm$ 10,0% entre la segmentation automatique et manuelle.

## 6. Conclusion

La segmentation d'images est au cœur de nombreux problèmes en imagerie médicale puisque bien souvent elle constitue la première étape d'un véritable flux de traitements d'image. Selon la suite à donner à ces images, certaines méthodes se révèlent plus probantes.

Le problème de la segmentation reste ouvert, au vu du grand nombre de publications régulièrement proposées sur le sujet. En effet, il n'existe pas de méthode générale fonctionnant pour tout type d'images, les techniques existantes étant optimisées pour une application donnée. Puisque la qualité du résultat est intrinsèquement subjective et que la finalité d'utilisation de la segmentation obtenue influe sur la perception de qualité de ce résultat, le choix d'une technique plutôt qu'une autre est assez ardu. Mais le choix d'une méthode dépend essentiellement des besoins de l'utilisateur.

## **Chapitre 3 :**

# **Une Méthode basée Deep Learning pour la segmentation des images CT du CORONA VIRUS**

## 1. Introduction

Après avoir présenté dans les parties précédentes un état de l'art sur l'utilisation des techniques du « *Deep Learning* » dans le domaine covid19, où on a présenter les approches, les techniques et les outils. Nous allons consacrer ce chapitre pour présenter en détail les modèles qu'on propose pour la segmentation d'anomalies et leur diagnostique dans les images à l'aide de deep learning.

## 2. Architecture de modèle proposée

Notre architecture représente les étapes nécessaires dans tout modèle de traitement des images basé sur l'apprentissage profond, nous collectons d'abord les données pulmonaire ,ensuit puis nous divisons des données en deux parties (données d'entraînement et test données) et pré-traitons, comme le montre la figure suivante.

Ensuite ,nous construisons un modèle U-net de training qui prend les entrées de données de traiter à l'étape précédente ,afin de calculer l'efficacité du modèle .

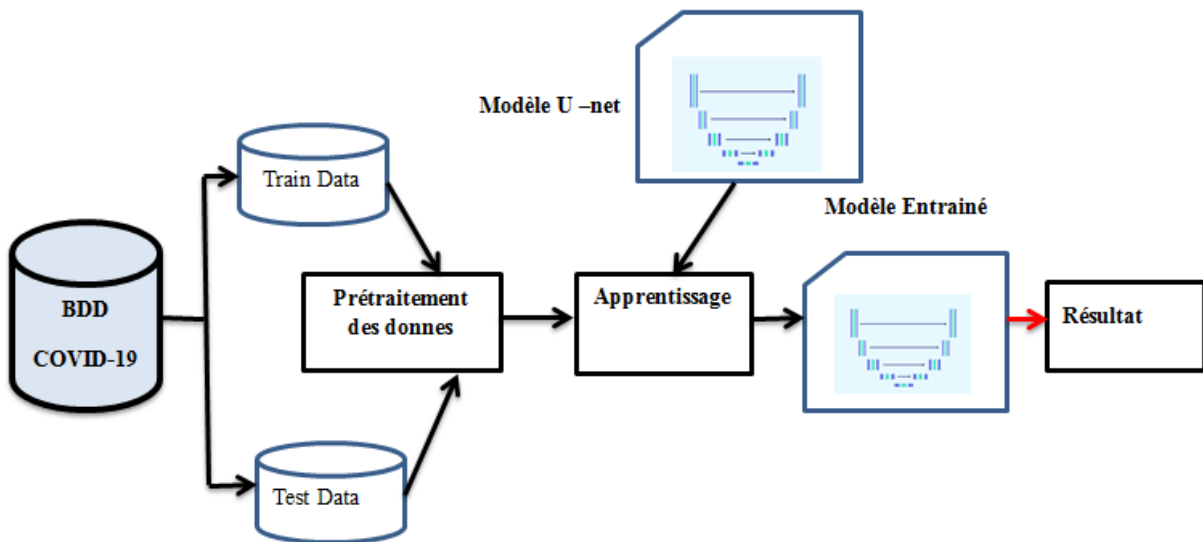


Figure 3. 1: Vue d'ensemble de modèle proposée.



### 3. Ressources utilisée

Avant de présenter notre approche, nous présentons le jeux de données (dataset) utilisé pour tester et évaluer notre démarche.

#### 3.1. Dataset

L'ensemble de données utilisé dans les expériences provient de la Société italienne de radiologie médicale et interventionnelle : ensemble de données de segmentation COVID-19 CT. L'ensemble de données-2 comprend 9 volumes, un total de 829 tranches, où 373 tranches ont été évaluées et segmentées par un radiologue en tant que cas COVID-19 [43].

#### 3.2. Ensembles d'apprentissage et d'évaluation

Dans la phase de division des données nous avons choisi de souffler les données et les diviser en deux parties (Train & Test) :

1. Train : Partie de jeux de données (échantillon) pour la phase l'apprentissage dans les réseaux de neurons de type DeepLearning.
2. Test : Partie de jeux de données (échantillon) utilisées uniquement pour évaluer les performances d'un modèle final.

#### 3.3. Prétraitement des données (Data pre-processing)

Toutes les images ont été converties au format PNG , elle ont été extraits de chaque image en appliquant son masque binaire , Le résultat a ensuite été redimensionné à (1024 \*1024), contenant les images et les étiquettes à utiliser pour la formation (training) et les tests.

Étant donné que les images ont été acquises à partir de différentes sources ,le redimensionnement des images était nécessaire .Toutes les images d'entrée ,y compris les tomodensitogrammes d'entraînement et de test ,ont été redimensionnées l'extrait suivant montre le chargement du dataset utilisée .

```
!git clone 'https://github.com/alexlaurence/NIfTI-Image-Converter.git'
```

### 4. Présentation des outils utilisés

Le python constitue le langage de référence dans le domaine de IA en particulier dans les domaines du deep learning.

#### 4.1. Le software

Plusieurs Framework et bibliothèques open sources sont disponibles dans la littérature, la grande majorité supporte le langage Python.

- La bibliothèque Numpy
- La bibliothèque OpenCV-python.
- La bibliothèque Tensorflow.
- La bibliothèque Scikit-image.
- La bibliothèque Pillow

#### 4.2. Le hardware

Cependant, vue les fortes exigences de calculs et espaces nécessaires pour l'implémentation des solutions à base de « *TensorFlow* » et « *Keras* », nous avons opté pour l'utilisation de calculs en *Cloud* via la plateforme « *Google Colab* ». Cette dernière offre la possibilité de calcul *GPU*, *TPU* et même *CPU*. C'est une plateforme gratuite pour des sessions de temps limitées sur le web. Elle utilise l'environnement « *Jupyter Notebook* » pour les différentes routines de programmation en langage Python.

### 5. La méthode U-Net(Convolutional Networks)

U-net est une architecture de réseau de neurones conçue principalement pour la segmentation d'images [44]. La structure de base d'une architecture U-net se compose de deux chemins. Le premier chemin est le chemin contractuel, également connu sous le nom de codeur ou chemin d'analyse. Le second est un chemin d'extension, également connu sous le nom de décodeur ou chemin de synthèse. Le réseau U-net a été développé sur la base des travaux de Long, J et al. [45] en utilisant des réseaux entièrement convolutifs. Leur mise en œuvre a obtenu de meilleures performances que la précédente meilleure sur le défi ISBI 2012 et a remporté le défi de suivi cellulaire ISBI en 2015, battant l'état du rayon à l'époque avec une marge considérable.

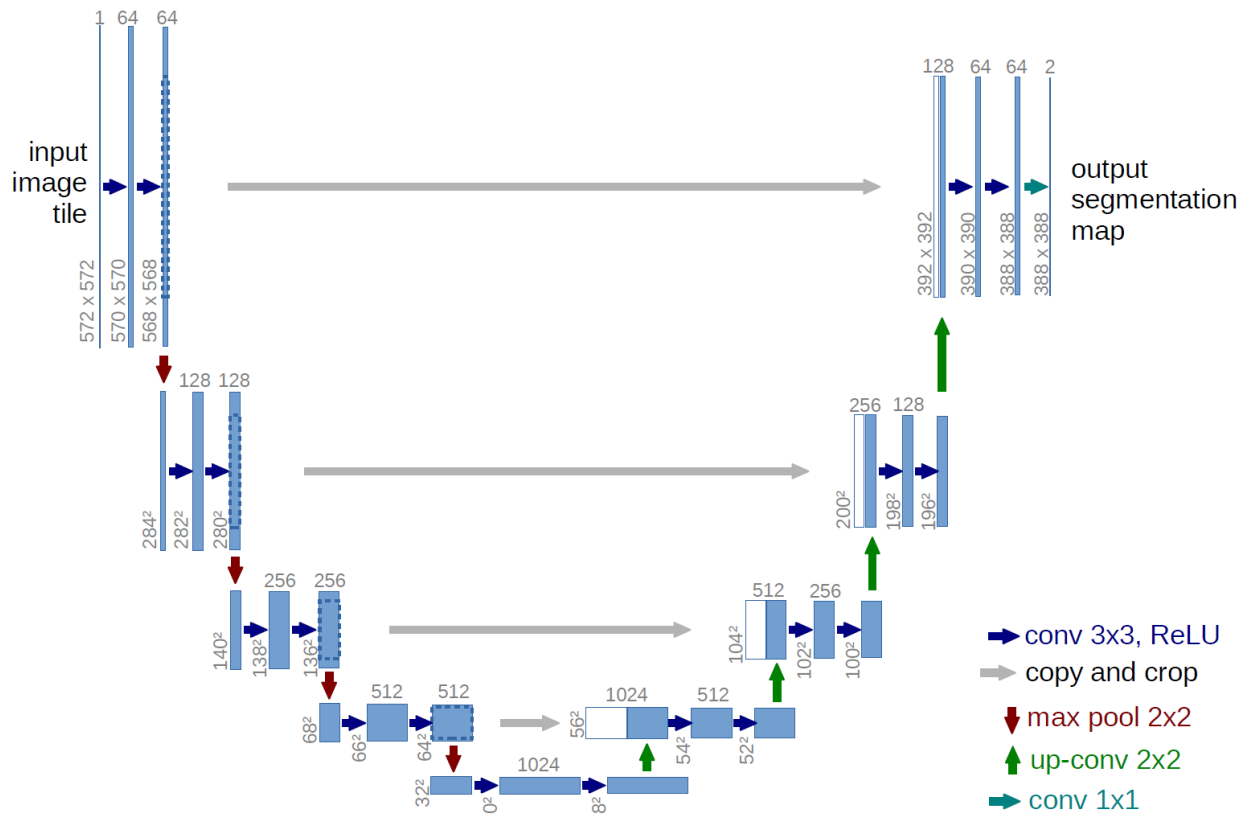


Figure 3. 2:U-Net architecteur.

Il se compose [46] :

**a .Chemin de contraction**

La mise en commun consécutive de deux fois 3×3 Conv et 2×2 max est effectuée. Cela peut aider à extraire des fonctionnalités plus avancées, mais cela réduit également la taille des cartes de fonctionnalités.

**b.Chemind'extension**

Une suite de 2×2 Up-conv et deux fois de 3×3 Conv est effectuée pour récupérer la taille de la carte de segmentation. Cependant, le processus ci-dessus réduit le « où » bien qu'il augmente le « quoi ». Cela signifie que nous pouvons obtenir des fonctionnalités avancées, mais nous perdons également les informations de localisation.

Ainsi, après chaque up-conv, nous avons également une concaténation de cartes de caractéristiques (flèches grises voir la figure 3 .2) qui sont au même niveau .Cela aide à donner les informations de localisation du chemin de contraction au chemin d'expansion.

À la fin,  $1 \times 1$  conv pour mapper la taille de la carte de caractéristiques de 64 à 2 puisque la carte de caractéristiques en sortie n'a que 2 classes, cellule et membrane.

## 6. Métrique évaluation

Nous avons utilisé deux métrique couramment trouvés dans la littérature :

### 6.1. Approximation de IoU

La métrique Intersection over Union (IoU), également appelée indice Jaccard, est essentiellement une méthode pour quantifier le pourcentage de chevauchement entre le masque cible et notre sortie de prédiction. Cette métrique est étroitement liée au coefficient Dice qui est souvent utilisé comme fonction de perte pendant l'entraînement.

$$\text{IoU} = \frac{\text{target} \cap \text{prediction}}{\text{target} \cup \text{prediction}}$$

Tout simplement, la métrique IoU mesure le nombre de pixels communs entre les masques cible et de prédiction divisé par le nombre total de pixels présents dans les deux masques .




Figure 3. 3:Exemple Iou.

### 6.2. Précision Métrique

La précision est intuitivement la capacité du classificateur à ne pas étiqueter comme positif un échantillon qui est négatif .

dans l'ensemble d'images et est défini par l'équation suivante :

$$\text{précision} = \frac{TP}{(TP + FP)}$$

## 7. Resultat et discussion

Les résultats des images de tomodensitométrie thoracique d'entrée et des anomalies détectées par U-Net sont illustrés à la Figure 3. 3(a et b). Dans la plupart des cas Le masque est bien visible.




Figure 3. 4:image CT thoracique a)Entrée dans l'architecture U-Net .




Figure 3. 5:image CT thoracique b)sortie la mask détectée par U-Net.

Pour notre model on a utilisé le model U-Net le nombre d'époque de 12.

Dans les figures suivantes , la précision de l'apprentissage augmente avec le nombre d'époque.

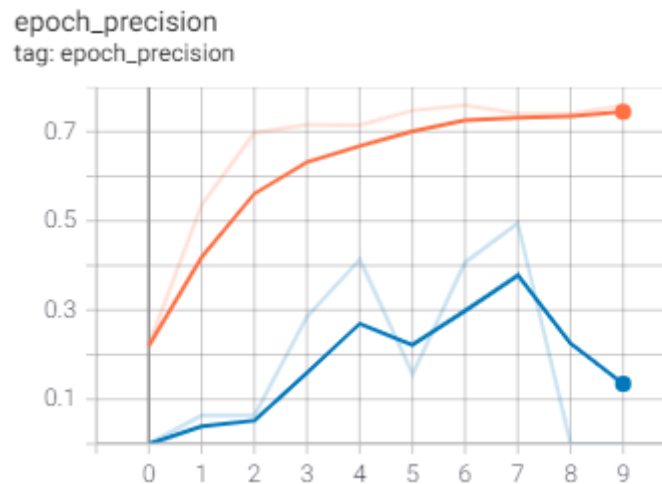


Figure 3. 6:precision de model

La vérification augmente de la même manière.

De même, l'erreur d'apprentissage augmente quelque peu, d'autre part, la validation diminue également avec

Le nombre d'époques. Ceci est dû au petit nombre d'époques par rapport à donner des résultats satisfaisants

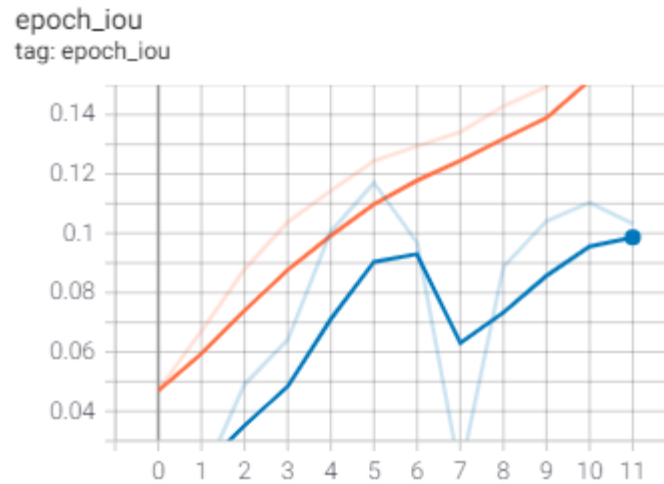


Figure 3. 7:: iou de model

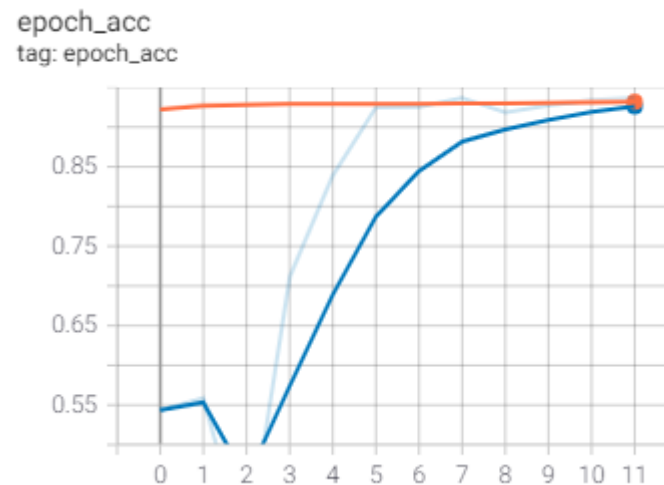


Figure 3. 8:acc de model

## 8. Conclusion

Dans ce dernier chapitre nous avons expliqué notre méthode de segmentation des images en utilisant le modèle U-net architecture, Donc nous présentons les ressources et outils utilisées

pour l'implémentation de notre modèle. Nous définissons la méthode U-net et leur architecture et la discussion des résultats obtenus.

Cependant les résultats que nous avons obtenus ne sont pas satisfaisants en raison du manque de materiale

## Conclusion Générale

Dans le manuscrit de ce mémoire de master nous avons abordé un sujet d'une importance particulière dans le traitement médical assisté par ordinateur dédié au Virus COVID-19. A cet effet ce manuscrit commence par la description de quelques notions médicales sur le covid19 traitant en particulier la segmentation des images de scanner pour générer des masques. Les images et les masques générés seront utilisés dans n'importe quel processus de détection et de classification du COVID19. Nous avons passé en revue différentes méthodes de segmentation que nous avons appliquées sur des images de la base de données covid19 disponible en open source à partir du site "<http://medicalsegmentation.com/covid19/>" ..

Nos travaux futurs seraient de généraliser le modèle proposé dans un plus large éventail de scénarios pratiques, tels que la facilitation avec le diagnostic de plus de types de maladies à partir d'images CT. En particulier, dans le cas d'une nouvelle maladie, telle que la détection et la classification du coronavirus. . La quantité de données de vérité terrain est généralement limitée étant donné la difficulté d'acquisition et d'annotation des données et vu que les méthodes du Deep Learning nécessitent une grande quantité de données, nous envisageons aussi une augmentation de données par des nouvelles techniques.



# Référence

1. Gorbalenya A.E., Baker S.C., Baric R.S. (sous presse); BioRxiv: 2020. Severe acute respiratory syndrome-related coronavirus: the species and its viruses – a statement of the coronavirus study group. [[Google Scholar](#)]
2. Jia H.P., Look D.C., Shi L. ACE2 receptor expression and severe acute respiratory syndrome coronavirus infection depend on differentiation of human airway epithelia. *J Virol.* 2005;79(23):14614–14621. [[Article PMC gratuit](#)] [[PubMed](#)] [[Google Scholar](#)]
3. Wu F., Zhao S., Yu B. *Nature.* (sous presse); 2020. A new coronavirus associated with human respiratory disease in China. [[Google Scholar](#)]
4. Zhang L., Shen F.M., Chen F., Lin Z. *Clin Infect Dis*; 2020. Lin. c1aa112. [[Article PMC gratuit](#)] [[PubMed](#)] [[Google Scholar](#)]
5. Tang X., Wu C., Li X. *Natl Sci Rev*; 2020. On the origin and continuing evolution of SARS-CoV-2. nwa036. [[Google Scholar](#)]
6. Xia S., Zhu Y., Liu M. *Cell Mol Immunol*; 2020. Fusion mechanism of 2019nCoV and fusion inhibitors targeting HR1 domain in spike protein; pp. 1–3. [[Article PMC gratuit](#)] [[PubMed](#)] [[Google Scholar](#)]
7. Pan F., Ye T., Sun P., Gui S., Liang B., Li L. Time Course of Lung Changes at
8. Chest CT during Recovery from Coronavirus Disease 2019 (COVID-19), *Radiology* 2020 Jun;295(3):715-721. doi: 10.1148/radiol.2020200370.
9. Organisation mondiale de la Santé. Tests diagnostiques pour le dépistage du SARS-CoV-2 : orientations provisoires, 11 septembre 2020. Genève, Organisation mondiale de la Santé, 2020. Référence de l’OMS :  
WHO/2019-nCoV/laboratory/2020.6. Disponible à l’adresse  
[https://apps.who.int/iris/bitstream/handle/10665/335724/WHO-2019-nCoV-laboratory-2020.6\\_e.pdf?sequence=1&isAllowed=y](https://apps.who.int/iris/bitstream/handle/10665/335724/WHO-2019-nCoV-laboratory-2020.6_e.pdf?sequence=1&isAllowed=y)
10. Biosafety in microbiological and biomedical laboratories, 5<sup>th</sup> Edition, CDC. Laboratory testing for middle East respiratory syndrome coronavirus, Interim guidance.(revised), January 2018. WHO/MERS/LAB/15.1/Rev1/2018
11. Haute Autorité de santé. Cahier des charges définissant les modalités d’évaluation des performances des tests sérologiques détectant les anticorps dirigés contre le Sars-CoV-2. Validée par le Collège le 16 avril 2020
12. Guo L., Ren L., Yang S. *Clin Infect Dis*; 2020. Profiling early humoral response to diagnose novel coronavirus disease (Covid-19) c1aa310. [[Article PMC gratuit](#)] [[PubMed](#)] [[Google Scholar](#)]

13. Zhao J., Yuan Q., Wang H. Clin Infect Dis; 2020. Antibody responses to Sars-CoV-2 in patients of novel coronavirus disease 2019. [[Article PMC gratuit](#)] [[PubMed](#)] [[Google Scholar](#)]
14. Haut Conseil de la santé publique Avis relatif aux recommandations thérapeutiques dans la prise en charge du COVID-19.  
<https://www.hcsp.fr/explore.cgi/avisrapportsdomaine?clefr=785> (Consulté le 30/03/2020)
15. Coronavirus disease 2019 (COVID-19) McIntosh K. Coronavirus disease 2019 (COVID-19) UpToDate Ed Wolters Kluwer.  
<https://www.uptodate.com/contents/coronavirus-disease-2019-covid-19/print> (Consulté le 30/03/2020)
16. I. Hadjidj, "Analyse des Images Mammographiques pour l'Aide à la Détection du Cancer du Sein," Abou Bekr Belkaid de Tlemcen, 2018.
17. Fang, Y. et al. Sensitivity of chest CT for COVID-19: comparison to RT-PCR. *Radiology*. <https://doi.org/10.1148/radiol.2020200432> (2020).
18. Yu, M. et al. Thin-section chest CT imaging of coronavirus disease 2019 pneumonia: comparison between patients with mild and severe disease. *Radiol. Cardiothorac. Imaging* <https://doi.org/10.1148/ryct.2020200126> (2020).
19. Xie, X. et al. Chest CT for typical 2019-nCoV pneumonia: relationship to negative RT-PCR testing. *Radiology*. <https://doi.org/10.1148/radiol.2020200343> (2020).
20. Inui, S. et al. Chest CT findings in cases from the cruise ship "Diamond Princess" with coronavirus disease 2019 (COVID-19). *Radiol. Cardiothorac. Imaging*. **2**, p.e200110 <https://doi.org/10.1148/ryct.2020200110> (2020)
21. Ai, T. et al. Correlation of chest CT and RT-PCR testing in coronavirus disease 2019 (COVID-19) in China: a report of 1014 Cases. *Radiology* <https://doi.org/10.1148/radiol.2020200642> (2020).
- 22 - J.P.Cocquerez, P. Foliguet, S.Maitre, Analyse d'images : Filtrage et segmentation, Collection Enseignement de la physique : mathématiques pour la physique, Masson, Paris, 1995.
- 23- W. Dou, "Segmentation d'images multispectrales basée sur la fusion d'informations : application aux images IRM", Thèse de doctorat en science à L'université de CAEN, 2006.
- 24- M. Naoui, "Segmentation d'images par modèle statistique de déforme et d'apparence : problématiques et contributions", Thèse de doctorat en science à l'université D'oran 1. 2007.
- 25- L.Lechlek, M .Ghoulal.2012''la segmentation d'image médicale par la méthode d'ensemble de niveaux (level sets)'' .Thésede Master, Université Larbi Ben M'hidi Oum El Bouaghi.
- 26- J. P. Cocquerez, S. Philipp, "Analyse d'images: filtrage et segmentation", Masson, Paris, 1995
- 27- R.Horand et O.Monga. «Vision par ordinateurs outils fondamentaux».2 éditions Edition Hermès, Paris ,1995.
- 28- Arnaud CAPRI "Caractérisation des objets dans une image en vue d'une aide à l'interprétation et d'une compression adaptée au contenu : application aux images échographiques". Université d'Orléans. Faculté des Sciences et Technologies Industrielles. Thèse de doctorat 2007.
- 29- H.Samet. «Region representation: quadtree from binary arrays.Computer Graphics and ImageProcessing ».1980.

- 30-** A. Capri, “Caractérisation des objets dans une image en vue d’une aide à l’interprétation et d’une compression adaptée au contenu : application aux images échographiques”, thèse de doctorat, université d’Orléans, Paris, 2007.
- 31-** “Segmentation d’images : principes”, [http://glotin.univtln.fr/MCBIR/Segmentation\\_images\\_principes.pdf](http://glotin.univtln.fr/MCBIR/Segmentation_images_principes.pdf), avril 2012.
- 32-** M. Sandeli. 2014 ” Traitement d’images par des approches bio-inspirées”. Thèse de magister, Université Constantine 2
- 33-** J. Rousselle, « Les contours actifs, une méthode de segmentation. Application à l’imagerie médicale ». Thèse de doctorat, Université de François Rabelais de Tours, Soutenue le 9 juillet 2003
- 34-** Cocquerez, J. P. and Philipp, S., Analyse d’images et segmentation. Masson, 1995. (Coello, et al., 1995) Coello, C. A. C. et al., Multiobjective design optimization of counterweight balancing of a robot arm using genetic algorithm. Seventh Int. Conf. on Tools with Arti. Intelli. (TAI’95), pp. 20-23, Novembre 5-8, 1995, Herndon (USA).
- 35-** J-C. Atine. Méthodes d’apprentissage flou : application à la segmentation d’images biologiques. PhDthesis, Institut national des sciences appliquées de Toulouse, 2005.
- 36-** J.-P.COCQUEREZ et S.PHILIPP, « Analyse d’images : filtrage et segmentation » , Paris, (février 2003)
- 37-** M. D. Zeiler and R. Fergus, “Visualizing and Understanding Convolutional Networks,” Springer, Cham, 2014, pp. 818–833
- 38-** A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, “A survey of the recent architectures of deep convolutional neural networks,” *Artif. Intell. Rev.*, pp. 1–70, 2020, doi: 10.1007/s10462-020-09825-6.
- 39-** X. Wang, X. Deng, Q. Fu, Q. Zhou, J. Feng, H. Ma, W. Liu and C. Zheng “A Weakly-Supervised Framework for COVID-19 Classification and Lesion Localization From Chest CT” *IEEE Transactions on Medical Imaging* ( Volume: 39, Issue: 8, Aug. 2020)
- 40-** L. Huang, R. Han, T. Ai, P. Yu, H. Kang, Q. Tao, et al., “Serial quantitative chest CT assessment of COVID-19: Deep-Learning Approach,” *Radiology: Cardiothoracic Imaging*, vol. 2, p. e200075, 2020.
- 41-** S. Jin, B. Wang, H. Xu, C. Luo, L. Wei, W. Zhao, et al., “AI-assisted CT imaging analysis for COVID-19 screening: Building and deploying a medical AI system in four weeks,” *MedRxiv*, 2020.
- 42-** F. Shan, Y. Gao, J. Wang, W. Shi, N. Shi, M. Han, et al., “Lung infection quantification of COVID-19 in CT images with deep learning,” *arXiv:2003.04655*, 2020.
- 43-** "<http://medicalsegmentation.com/covid19/>"
- 44-** O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” 2015, pp. 234–241.
- 45-** J. Long, E. Shelhamer, and T. Darrell, “Fully convolutional networks for semantic

références

segmentation,” 2015, pp. 3431–3440

**46-[U-Net: Convolutional Networks for Biomedical Image Segmentation](#)**