



جامعة أبو بكر بلقايد - تلمسان

Université Abou Bakr Belkaïd de Tlemcen

Faculté de Technologie

Département de Génie Biomédical

Laboratoire de Recherche de Génie Biomédical

**MEMOIRE DE PROJET DE FIN D'ETUDES**

Pour l'obtention du Diplôme de

**MASTER en GENIE BIOMEDICAL**

**Spécialité : Imagerie Médicale**

Présenté par : KIES Riheb et KRIM Samira

---

**Extraction du réseau rétinien par la méthode de  
Deep Learning pour l'aide au diagnostic en  
Ophtalmologie**

---

Soutenu le 04 juillet 2021 devant le Jury

M.	MESSADI Mohamed	<i>Prof</i>	Université de Tlemcen	Président
Mme.	FEROUI Amel	<i>MCA</i>	Université de Tlemcen	Encadrante
Mme.	ELAOUABER Zineb Aziza	<i>Doctorante</i>	Université de Tlemcen	Co-Encadrante
M.	LAZOUNI Mohamed El Amine	<i>MCA</i>	Université de Tlemcen	Examineur

**Année universitaire 2020-2021**

## **Remerciement**

Tout d'abord, nous remercions Dieu le tout-puissant de nous avoir donné le courage et la volonté de faire ce travail humble.

Avec tout le respect, nous tenons à remercier vivement tout le corps enseignant de l'université Abou Bekr Belkaïd de Tlemcen qui nous a suivis tout au long de nos études.

On adresse nos vifs remerciements à Mme FEROUJ Amel et Mlle ELAOUABER Zineb Aziza, en tant que encadreur et Co-encadreur de notre projet de fin d'étude pour leur écoute et disponible tout au long de la réalisation de ce travail malgré leur charges pédagogiques.

Et surtout pour leur patience et leurs judicieux conseils.

Nous tenons aussi à remercier les membres du jury Mr MESSADI Mohamed et Mr LAZOUNI Mohamed El Amine, pour bien vouloir nous accorder de leur temps précieux pour critiquer, discuter et juger notre travail.

## **Dédicaces**

Je dédie ce travail à :

Ma mère avec toute mon affection

Mon père avec toute ma reconnaissance

Mes chères sœurs

Mon frère

Ma binôme Samira

Mes amis

Et à Mlle ELAOUABER Zineb Aziza

## **Dédicaces**

Je dédie ce travail à :

Mes chers parents

Mes chers frères et sœurs

Ma binôme bien aimée Riheb

Mes amis

Et surtout à Mlle ELAUBER Zineb Aziza pour son aide si précieuse

**KRIM Samira**

# Résumé

Les modifications de la structure vasculaire sanguine sont la première indication qu'une personne est affectée par une maladie. Diverses maladies sont diagnostiquées par l'examen de la structure des vaisseaux sanguins rétiniens comme la rétinopathie diabétique. L'extraction manuelle est difficile, donc, l'automatisation de ce processus est importante. Dans ce travail, nous nous concentrons sur l'utilisation de l'apprentissage profond et des réseaux de neurones convolutifs (CNN) pour la segmentation précise du réseau rétinien. Pour cela, nous avons appliqué trois différentes architectures : SegNet, U-Net et le réseau convolutif profond (CNN), ces architectures nécessitent une large base de données étiquetée, donc nous avons affecté une étape d'augmentation d'images en appliquant des transformations géométriques. L'étape d'apprentissage est coûteuse en termes de temps, dans ce travail, nous avons utilisé MATLAB R2019b compatible avec un GPU pour minimiser le temps de calcul. Ces méthodes ont été testées sur les trois bases de données publiques annotées DRIVE, HRF et CHASE-DB1. Ainsi, les résultats obtenus étaient satisfaisants et encourageants en comparaison avec les méthodes existantes.

**Les mots clés:** Réseau rétinien, DEEP LEARNING, Réseaux de neurones convolutionnels, Segmentation sémantique, Images fond d'œil.

## Abstract

Changes in the blood vessel structure are the first indication that a person is affected by a disease. A variety of diseases are diagnosed by examining the structure of the retinal blood vessels, such as diabetic retinopathy. Manual extraction is difficult, therefore, automating this process is important. In this work, we focus on the use of deep learning and convolutional neural networks (CNNs) for precise segmentation of the retinal network. For this we have applied three different architectures: SegNet, U-Net and Deep Convolutional Network (CNN), these architectures require a large tagged database, so we assigned an image augmentation step by applying transformations geometric. The learning step is time consuming, in this work we used GPU compatible MATLAB R2019b to minimize compute time. These methods were tested on the three annotated public databases DRIVE, HRF and CHASE-DB1. Thus, the results obtained were satisfactory and encouraging in comparison with the existing methods.

**Key words:** Retinal network, DEEP LEARNING, Convolutional neural networks, Semantic segmentation, Fundus images.

## ملخص

التغيرات في بنية الأوعية الدموية هي أول مؤشر على إصابة الشخص بمرض. يتم تشخيص مجموعة متنوعة من الأمراض عن طريق فحص بنية الأوعية الدموية في شبكية العين، مثل اعتلال الشبكية السكري. الاستخراج اليدوي صعب، لذلك فإن جعل هذه العملية أوتوماتيكية هو أمر مهم. في هذا العمل، نركز على استخدام التعلم العميق والشبكات العصبية التلافيفية (CNNs) للتجزئة الدقيقة للشبكية. لهذا قمنا بتطبيق ثلاث بنيات مختلفة: SegNet و U-Net و Deep Convolutional Network (CNN)، تتطلب هذه البنى قاعدة بيانات كبيرة بعلامات، لذلك قمنا بزيادة عدد الصور عن طريق تطبيق التحويلات الهندسية. تستغرق خطوة التعلم وقتاً طويلاً، وفي هذا العمل استخدمنا MATLAB R2019b المتوافق مع وحدة معالجة الرسومات لتقليل وقت الحوسبة. تم اختبار هذه الطرق على ثلاث قواعد بيانات عامة مشروحة CHASE-DB1 و HRF و DRIVE. وبذلك كانت النتائج التي تم الحصول عليها مرضية ومشجعة مقارنة بالطرق الحالية.

**الكلمات المفتاحية:** الشبكية، التعلم العميق، الشبكات العصبية التلافيفية، التجزئة الدلالية، صور قاع العين.

# Table des matières

Table des figures	
Liste des tableaux	
Liste des acronymes	
Introduction générale .....	1
<b>Chapitre I: Contexte Médical</b>	
I.1.Introduction.....	4
I.2.Description générale de l'œil.....	4
I.3.Anatomie de la rétine .....	5
I.4.Les Pathologies Rétiniennes.....	6
I .4.1.La rétinopathie diabétique .....	6
I.4.2. Dégénérescence maculaire liée à l'âge (DMLA) .....	7
I .4.3. Le décollement de rétine.....	8
I .4.4.Les membranes épirétiniennes et trous maculaires .....	8
I .5.Techniques d'Acquisition des Images Rétiniennes.....	9
I .5.1. Rétinographe mydriatique(RM) et non mydriatique(RNM).....	9
I .5.2. Angiographie a la fluorescence.....	9
I .5.3. Nouvelles techniques d'imagerie rétinienne.....	10
I .6.Conclusion.....	10
<b>Chapitre II: Apprentissage Profond (Deep Learning)</b>	
II.1. Introduction.....	13
II.2. Principe des réseaux de neurones.....	13
II.2.1. Réseaux de neurones biologiques .....	13
II.2.2. Les réseaux de neurones artificiels .....	14
II.2.3. Apprentissage profond (Deep Learning).....	14
II.2.4. Les réseaux de neurones convolutifs .....	15
II.2.4.1. Les différentes couches des réseaux de neurones convolutifs.....	16
A. Couche de convolution (CONV) .....	16
B. Couche de pooling (POOL).....	17
C. Couche de correction (ReLU) .....	18



D. Couche entièrement connectée (FC) .....	18
E. Couche de dé-convolution.....	19
F. Couche de perte (LOSS) .....	19
G. Couche de normalisation .....	19
H. Couche de régularisation (Drop out) .....	19
II.2.4.2. Avantages des CNN .....	19
II.2.4.3. Inconvénients des CNN .....	20
II.3. Architectures du Deep Learning.....	20
II.3.1. SegNet .....	20
II.3.2. UNet .....	21
II.3.3. Réseaux de neurones entièrement connectés (FCN) .....	22
II.4. Les options d'apprentissage.....	22
II.4.1. Optimiseurs.....	22
II.4.2. Epoque.....	22
II.4.3. Taux d'apprentissage.....	23
II.4.5. Fréquence de validation (ValidationFrequency).....	23
II.4.5. MiniBatchSize.....	23
II.4.6. Ressource matérielle.....	23
II.5. Etat de l'art.....	24
II.6. Conclusion.....	27
 <b>Chapitre III: Expérimentation, Résultats et Discussions</b>	
III.1. Introduction.....	29
III.2. Description de la base de données.....	30
III.2.1. Base d'images « DRIVE ».....	30
III.2.2. Base d'images « HRF » .....	30
III.2.3. Base d'images « CHASE_DB1 ».....	31
III.3. Matériels et méthodes.....	31
III.3.1. Matériels utilisés .....	32
III.3.1.1. Le software .....	32

III.3.1.2. Le hardware .....	32
III.3.2. Méthodes proposées.....	33
III.3.2.1. Préparation des données.....	33
III.3.2.1.1 Prétraitement.....	33
III.3.2.1.2. Augmentation des bases d'images.....	34
III.3.2.2. Extraction du réseau vasculaire rétinien.....	35
III.3.2.2.1. Architecture 01 : SegNet .....	35
III.3.2.2.2. Architecture 02 : U-Net.....	36
III.3.2.2.3. Architecture 03 : CNN Simple.....	37
III.4. Résultats et discussion.....	38
III.5. Interface graphique développée.....	44
III.6. Conclusion .....	46
Conclusion générale.....	47
Bibliographie.....	49

# Liste des figures et tableaux

## Liste des figures

### Chapitre I : Contexte Médical

Figure I.1 : L'œil .....	4
Figure I.2 : La rétine.....	6
Figure I.3 : La rétinopathie diabétique .....	7
Figure I.4 : DMLA .....	7
Figure I.5 : Décollement de rétine par trou maculaire .....	8
Figure I.6 : Membrane épirétinienne .....	8
Figure I.7 : Trou maculaire avant chirurgie .....	9
Figure I.8 : Trou maculaire après chirurgie .....	9
Figure I.9 : RNM.....	9
Figure I.10 : Angiographie à la fluorescéine de la rétine .....	10

### Chapitre II: Apprentissage Profond (Deep Learning)

Figure II.1: Neurone Biologique .....	14
Figure II.2 : RNB vs RNA.....	14
Figure II.3: Les couches d'un réseau neuronal convolutionnel .....	16
Figure II.4 : Max Pooling avec un filtre de taille 2x2 et un pas de 2 .....	17
Figure II.5: Allure de la fonction d'activation ReLU.....	18
Figure II.6: L'architecture SegNet.....	21
Figure II.7: L'architecture U-Net.....	21
Figure II.8: FCN.....	22
Figure II.9: L'architecture proposée par Wang et al .....	24
Figure II.10: L'architecture proposée par P. Liskowski et al .....	25
Figure II.11 : L'architecture proposée BTS-DSN par Song Guo et al .....	25
Figure II.12: L'architecture proposée par Juntang Zhuang .....	26

### Chapitre III : Expérimentation, Résultats et Discussions

<b>Figure III.1</b> : Exemple de la base DRIVE.....	30
<b>Figure. III .2</b> : Exemple de la base HRF.....	31
<b>Figure III.3</b> : Exemple de la base CHASE_DB1.....	31
<b>Figure III.4</b> : L’environnement MATLAB R2019 .....	32
<b>Figure III.5</b> : Les ressources matérielles.....	32
<b>Figure III.6</b> : Schéma général de notre méthode.....	33
<b>Figure III.7</b> : Exemple de prétraitement.....	34
<b>Figure.III.8</b> : Exemples d’augmentation d’images.....	35
<b>Figure III.9</b> : Architecture SegNet utilisée.....	36
<b>Figure III.10</b> : Architecture U-Net proposée.....	37
<b>Figure III .11</b> : Architecture CNN proposée.....	38
<b>Figure III.12</b> : Progression de l’apprentissage de nos architectures.....	40
<b>Figure III 13</b> : Exemple du résultat du réseau rétinien à partir de la base DRIVE.....	41
<b>Figure III 14</b> : Exemple du résultat du réseau rétinien à partir de la base HRF .....	41
<b>Figure III 15</b> : Exemple du résultat du réseau rétinien à partir de la base CHASE_DB1...	42
<b>Figure III.16</b> : Exemple de notre interface développée.....	46

### Liste des tableaux

<b>Tableau II.1.</b> L’architecture proposée par Martina Melinscak .....	26
<b>Tableau III.1.</b> Performances obtenus et comparaison des résultats avec l’état de l’art en utilisant la base de données <b>DRIVE</b> .....	43
<b>Tableau III.2.</b> Performances obtenus et comparaison des résultats avec l’état de l’art en utilisant la base de données <b>HRF</b> .....	43

**Tableau III.3.** Performances obtenus et comparaison des résultats avec l'état de l'art en utilisant la base de données

<b>CHASE_DB1</b> .....	43
------------------------	----

## Liste des acronymes

**RD** : La rétinopathie diabétique

**RNM** : Rétinographie Non Mydriatique ou dilaté.

**RM** : Rétinographie Mydriatique.

**OCT** : Optical Coherence Tomography (La tomographie à Cohérence Optique).

**RNA** : Un réseau de neurones artificiel.

**CNN** : Convolutional Neural Network (réseau de neurones convolutif).

**CONV** : Couche de convolution.

**POOL** : Couche de pooling.

**ReLU** : Rectified Linear Units (Fonction d'Activation non Saturante).

**FC** : Fully Connected (Couche entièrement connectée).

**LOSS** : Couche de perte.

**BDD** : Base De Données.

**FCN** : Fully Connected Network.

**CPU** : Central Processing Unit (unité centrale de traitement).

**GPU** : Graphical Processing Unit (unité graphique de traitement).

**RF** : Random Forest.

**DRIVE** : Digital Retinal Images for Vessel Extraction.

**STARE** : STructured Analysis of the Retina.

**BTS-DSN** : Deeply Supervised Neural Network with Short Connections for Retinal Vessel Segmentation.

**AUC** : Area Under Curve (aire sous la courbe ROC).

**MP** : Max pooling.

**HRF** : High Resolution Fundus.

**FOV** : Field of View (champ de vision).

**JPEG** : Joint Photographic Experts Group.

**CHASE** : Child Heart and Health Study in England.

**MATLAB** : Matrix Laboratory.

**VP** : Vrais Positifs.

**FP** : Faux Positifs.



**FN** : Faux Négatifs.

**VN** : représentent Négatifs.

**Se** : Sensibilité

**Sp** : Spécificité

**Acc** : Accuracy (Précision).

**IoU** : l'indice de Jaccard.

## Introduction générale

La segmentation d'images est une procédure importante dans de nombreux systèmes de diagnostic médical. Appliquée à des images microscopiques de la rétine pour détecter des vaisseaux et des lésions, elle contribue au diagnostic de plusieurs maladies comme la rétinopathie diabétique, la dégénérescence maculaire liée à l'âge DMLA et le glaucome.

Actuellement, l'utilisation des images du fond d'œil pour la détection et l'analyse des pathologies est de plus en plus large. En observant les changements des vaisseaux, des lésions rétinienne peuvent être trouvées. Par conséquent, les informations des images du fond d'œil jouent un rôle important dans la découverte précoce de la maladie. Récemment et grâce à l'Intelligence Artificielle, elles sont utilisées même pour la prédiction des maladies cardiaques

Dans ce travail, nous avons réalisé un système d'aide au diagnostic en ophtalmologie, en basant sur la segmentation sémantique du réseau rétinien.

La segmentation manuelle des vaisseaux sanguins soit possible, il s'agit d'un travail fastidieux, monotone, long et répétitif qui nécessite des compétences professionnelles, et donc ce n'est pas une procédure réalisable en termes de temps et de main-d'œuvre.

Étant donné que les structures fines sont des objets dont au moins une dimension est très petite par rapport aux autres. Elles sont donc difficilement préservées dans un contexte multi échelle, et leur segmentation à partir des images pose par conséquent des difficultés aux méthodes classiques basées sur la morphologie mathématique par exemple.

Pour cela, nous utilisons des architectures de l'apprentissage profond et les réseaux de neurones convolutifs (CNN) pour la segmentation de l'arbre vasculaire rétinien.

Ces architectures nécessitent une large base de données étiquetée, afin de résoudre ce problème, nous effectuons une augmentation d'images par l'application des transformations géométriques.

Ensuite, la segmentation sémantique du réseau rétinien est déployée en utilisant trois architectures du deep learning différentes. Ce travail est testé sur trois bases de données publiques DRIVE, HRF et CHASE\_DB1.

Ce mémoire s'organise en 3 chapitres :

### **Chapitre I : Contexte Médical**

Dans le premier chapitre, nous allons parler brièvement de la structure anatomique de l'œil, ensuite les différentes maladies affectant l'œil et le réseau rétinien et finalement nous



présenterons, les systèmes d'acquisition des images rétiniennes comme l'angiographie et la rétino-graphie.

### **Chapitre II : Apprentissage Profond (Deep Learning)**

Nous définirons dans ce chapitre, les notions de base des réseaux de neurones convolutifs et nous donnerons aussi un bref aperçu des architectures de la segmentation sémantique les plus utilisées. Nous citons aussi quelques travaux existants dans la littérature pour la segmentation du réseau rétinien par deep learning.

### **Chapitre III: Expérimentation, Résultats et Discussions**

Ce chapitre est consacré à la présentation des modèles du deep learning que nous utiliserons pour l'extraction du réseau rétinien, et nous discuterons par la suite sur les résultats obtenus. En outre, nous effectuons une comparaison entre les résultats obtenus par les différentes architectures.

A la fin de ce chapitre nous présentons l'interface créée dans ce projet de fin d'étude.

# **CHAPITRE I : Contexte Médical**

## I.1. Introduction

La vision est un processus assuré par une chaîne complexe dont l'œil est le capteur. Ce capteur perçoit la lumière et la transforme en messages nerveux à destination du cerveau qui en assure le traitement.

L'œil est l'un des organes les plus perfectionnés de notre corps. Il est constitué sur le plan fonctionnel, d'un système optique assurant la transmission de la lumière et d'un système photosensible qui assure la transduction, c'est-à-dire la transformation en un message neurologique, des photons lumineux d'une image rétinienne d'une qualité optique relativement médiocre, alors que l'acte final perceptif est une vision précise [1].

Ce chapitre est consacré à la présentation du contexte médical sur l'œil et en particulier de la rétine ainsi qu'aux anomalies du fond d'œil et la présentation des moyens d'acquisition actuels d'imagerie rétinienne.

## I.2. Description générale de l'œil

L'œil ou globe oculaire est l'organe principal de la vision, il permet de capter le signal lumineux avant que l'information ne soit réinterprétée par le cerveau et transformée en formes et en couleurs. Le globe oculaire est grossièrement sphérique, d'environ 24 mm de diamètre, pèse 7 grammes et de faible volume  $6.5 \text{ cm}^3$  [2]. La figure I.1 présente le schéma de l'anatomie de l'œil.

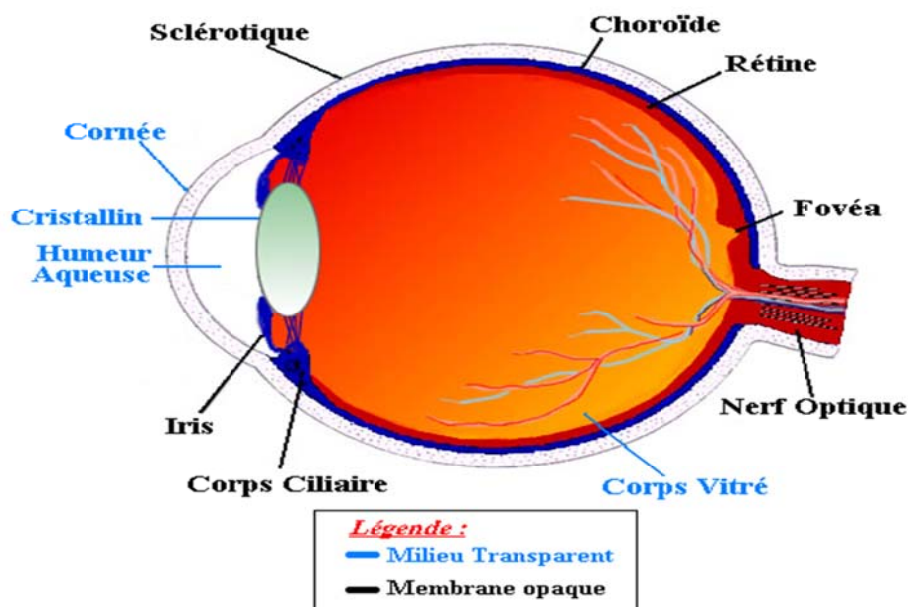


Figure I.1. Schéma de l'anatomie de l'œil.

La paroi du globe oculaire est formée de 3 tuniques [3] et des milieux transparents:

- La tunique fibreuse, externe, se compose de la sclérotique opaque en arrière et de la cornée transparente en avant. La sclérotique : c'est une membrane rigide qui donne sa forme à l'œil.
- La tunique uvéale, dite aussi uvée, se compose de trois éléments : l'iris en avant, le corps ciliaire et la choroïde en arrière. L'iris est la portion la plus antérieure de l'uvée, il est de structure pigmentée, donnant sa couleur à l'œil et percé d'un trou, la pupille.
- La tunique nerveuse se compose de la rétine, que nous étudierons précisément plus tard. C'est elle qui traduit les rayons lumineux en influx nerveux.
- L'humeur aqueuse : c'est un liquide transparent qui remplit l'espace entre la cornée et le cristallin, est un liquide continuellement renouvelé et qui, avec le corps vitré, maintient la pression oculaire.
- Le cristallin : c'est la lentille de l'œil qui permet la mise au point par sa propriété essentielle qu'est sa plasticité qui lui permet de focaliser la lumière sur la rétine en modifiant ses courbures lors de l'accommodation.
- Le corps vitré : c'est une masse gélatineuse et transparente, contenant 99% d'eau et représentant 60% du volume oculaire. Le corps vitré maintient la rétine contre les parois de l'œil.

### I.3. Anatomie de la rétine


Tapissant le fond de l'œil, la rétine visuelle ou nerveuse est le lieu de traduction du message lumineux venant de l'extérieur en signaux nerveux envoyés au cerveau. Il s'agit d'un tissu neuronal très fin, qui fait partie du Système Nerveux Central, de 0,1 à 0,5 mm d'épaisseur, organisée en dix couches de cellules. Celles-ci comprennent l'épithélium pigmentaire, la couche des photorécepteurs, la membrane limitante, la couche granuleuse et la couche plexiforme externes et internes, la couche des ganglionnaires, la couche des fibres optiques et finalement la membrane limitante interne [3].

Pour simplifier, nous parlerons ici uniquement de trois couches qui nous intéressent : la couche des cellules photosensibles comprenant la couche des photorécepteurs (cônes et bâtonnets) et la couche granuleuse externe, la couche granuleuse interne et la couche des cellules ganglionnaires. Ces trois couches représentent les cellules nerveuses de la rétine, reliées entre elles et ayant chacune une fonction précise [3].

- **Les cônes** : responsables de l'acuité visuelle et de la vision des couleurs, sont majoritaires sur la macula et seuls présents dans la fovéa.

- **Les bâtonnets** : sensibles à la quantité de la lumière et à son intensité, et responsables de la vision dans des conditions de faible éclairage, se distribuent sur l'ensemble de la rétine et permettent l'élargissement du champ visuel, ou vision périphérique.
- **Les cellules bipolaires** : mettent en relation les cellules photo réceptrices et les cellules ganglionnaires.
- **Les cellules ganglionnaires** : se prolongent par les fibres optiques, qui se réunissent dans la papille pour former le nerf optique.

La figure I.2 suivante présente les différentes couches et cellules de la rétine.



**Figure I.2.** Les différentes couches de la rétine.

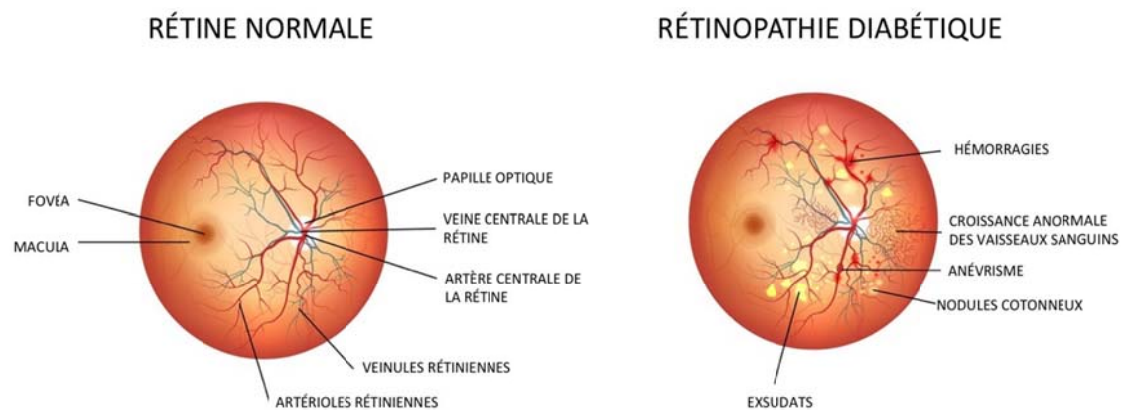
### I.4. Les pathologies rétinienne

Plusieurs pathologies oculaires peuvent affecter la rétine et le réseau vasculaire rétinien, entraînant des changements géométriques de l'arbre vasculaire et la naissance des néo-vaisseaux ainsi que l'apparition des lésions sur la surface de la rétine. La majorité de ces pathologies sont liées à des maladies cardiovasculaires, parmi eux nous citons :

#### I.4.1. La rétinopathie diabétique

La rétinopathie diabétique est une grave complication du diabète et la conséquence d'une hyperglycémie de longue durée. Elle est caractérisée par l'apparition des lésions rétinienne (micro-anévrysmes, hémorragies...) pouvant conduire à la cécité en absence d'un traitement adapté.


Les anomalies rétiniennes qui caractérisent la rétinopathie diabétique suivent une évolution prédictible sans variations majeures dans leur ordre d'apparition. Cette maladie est le résultat de troubles vasculaires rétiniens. Les stades précoces se caractérisent par des occlusions et des dilatations vasculaires rétiniennes. Ensuite elle évolue vers une rétinopathie proliférative avec apparition de néo-vaisseaux. L'œdème maculaire qui peut apparaître réduit souvent considérablement la vision (figure I.3) [4].



**Figure I.3.** Fond d'œil montrant la différence entre la rétine normale et la rétinopathie diabétique.

### I.4.2. Dégénérescence maculaire liée à l'âge (DMLA)

Une autre maladie de la rétine qui a un effet similaire à la rétinopathie diabétique, mais d'autres causes est la dégénérescence maculaire liée à l'âge (DMLA). Elle apparaît après l'âge de cinquante ans et entraînant une altération de la fonction rétinienne maculaire donc de la vision centrale. La prévalence globale de la maladie est de 8% après 50 ans. Cette prévalence globale augmente progressivement avec l'âge (figure I.4) [5].



**Figure I.4.** DMLA exsudative.

### I.4.3. Le décollement de rétine

C'est une affection grave d'apparition souvent rapide, nécessitant une prise en charge chirurgicale. C'est le décollement d'une partie de la surface de la rétine de son support

(l'épithélium pigmentaire) avec du liquide qui s'interpose entre ces deux feuillets. Il est le plus souvent secondaire à la présence de déchirure sur la rétine

Les principaux facteurs de risque sont la myopie, le décollement postérieur du vitré, les antécédents de décollement de la rétine dans l'autre œil et les antécédents de chirurgie de la cataracte (Figure I.5) [6].



**Figure I.5.** Décollement de rétine par trou maculaire dans le cas d'une myopie forte.


#### I.4.4. Les membranes épitréiniennes et trous maculaires

Des membranes peuvent se former en surface de la rétine maculaire, la macula étant la partie toute centrale de la rétine. Elles sont fréquentes dans la population générale, mais une prise en charge chirurgicale n'est nécessaire que si l'acuité visuelle s'altère notablement ou que des déformations gênantes apparaissent (Figure I.6) [6].


Des trous maculaires peuvent également apparaître dans la partie centrale de la rétine, entraînant une importante baisse de la vision et des déformations. Le traitement est exclusivement chirurgical, sous simple anesthésie locale, par des microincisions transconjonctivales. Un positionnement postopératoire est indispensable (Figure I.7) (Figure I.8) [6].



**Figure I.6.** Membrane épitréinienne dans l'œil droit.



**Figure I.7.** Trou maculaire avant chirurgie.



**Figure I.8.** Trou maculaire après chirurgie.

### I.5. Techniques d'acquisition des images rétinienne

Dans cette section du chapitre, nous présentons les différents appareils permettant l'acquisition des images couleur du fond d'œil.

#### I.5.1. La rétinographie

C'est un examen simple et indolore permettant d'examiner le fond de l'œil en réalisant des photographies couleurs du fond d'œil. Cette procédure de diagnostic peut être effectuée sur un œil dilaté (Rétinographie Non Mydriatique RNM) ou dilaté (Rétinographie Mydriatique RM) qui donne des clichés de bonne qualité, afin d'observer et analyser la rétine et ses vaisseaux, la papille optique (tête du nerf optique) et la macula.

Le fond d'œil est souvent prescrit par les médecins traitants, particulièrement dans le cadre de la surveillance d'affections telles que le diabète ou l'hypertension artérielle. Il permet de dépister des inflammations, des tumeurs ou un décollement de la rétine. Le fond d'œil permet aussi d'évaluer et de suivre les atteintes vasculaires liées à certaines pathologies (figure I.9) [7].



**Figure I.9.** Rétinographe Non Mydriatique RNM.

#### I.5.2. Angiographie à la fluorescence

Cet examen consiste en la prise de photographies du fond d'œil après injection intraveineuse d'un colorant fluorescent (fluorescéine, vert d'indocyanine). Il permet une étude détaillée des



vaisseaux sanguins pour établir le diagnostic de certaines maladies ou guider un traitement, par exemple, lorsqu'une photo-coagulation au laser est envisagée. Les indications essentielles sont la rétinopathie diabétique et les dégénérescences maculaires (figure I.10) [8].



Figure I.10. Angiographe à la fluorescéine.

### I.5.3. Nouvelles techniques d'imagerie rétinienne

- **L'angio OCT** : nouvel appareil permettant de visualiser les capillaires rétiniens,
- **Système d'imagerie grand champ** : permettant de visualiser les pathologies rétiniennes périphériques,
- **Angiographe / OCT Spectralis** : permettant de réaliser une imagerie rétinienne de haute qualité [9].

### I.6. Conclusion

Dans ce chapitre, nous avons présenté une description globale de l'anatomie de l'œil et de la rétine, les pathologies les plus sévères et les plus répandues qui affectent la rétine, ainsi que les appareils permettant l'acquisition des images fond d'œil couleurs.

Dans le chapitre suivant, nous parlerons de quelques travaux existant dans la littérature concernant l'extraction du réseau rétinien ainsi que le principe des réseaux de neurones profonds (Deep Learning) et les différentes architectures utilisées pour la segmentation sémantique.

# **CHAPITRE II: Apprentissage Profond**

## **(Deep Learning)**

### II.1. Introduction

L'intelligence artificielle est une discipline scientifique recherchant des méthodes pour résoudre de problèmes à forte complexité logique ou algorithmique. L'apprentissage automatique est le champ d'étude de l'intelligence artificielle. Par conséquent, L'apprentissage profond (en anglais Deep Learning) est un ensemble de méthodes d'apprentissage automatique tentant à modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

Ce chapitre est consacré à la présentation du principe des réseaux de neurones profonds (Deep Learning) et les différentes architectures utilisées pour la segmentation sémantique. Nous présenterons, ensuite, les différents travaux cités dans la littérature pour la détection du réseau vasculaire rétinien.

### II.2. Principe des réseaux de neurones

Un réseau de neurones est un outil puissant de la modélisation des relations complexes entre les données d'entrée et de sortie. Le développement de cette technologie a été motivé par l'ambition d'avoir un système artificiel capable d'accomplir des tâches intelligentes de manière semblable à celles qui sont exécutées par le cerveau humain.

#### II.2.1. Réseaux de neurones biologiques

Le système nerveux est composé de milliards de cellules : c'est un réseau de neurones biologiques (RNB). En effet, les neurones ne sont pas indépendants les uns des autres, ils établissent entre eux des liaisons et forment des réseaux plus ou moins complexes. Le neurone biologique est composé de trois parties principales :

- Le corps cellulaire : composé du centre de contrôle traitant les informations reçues par les dendrites.
- Les dendrites : sont les principaux fils conducteurs par lesquels transitent l'information venue de l'extérieur.
- L'axone : est le fil conducteur qui conduit le signal de sortie du corps cellulaire vers d'autres neurones (figure.II.1) [11].




Figure II.1. Neurone Biologique.

### II.2.2. Les réseaux de neurones artificiels

Un réseau de neurones artificiel (RNA) (ou Artificial Neural Network ANN, en anglais) est un système informatique s'inspirant du fonctionnement du cerveau humain pour apprendre une information [12]. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissage de type probabiliste. Ils sont placés d'une part dans la famille des applications statistiques, qu'ils enrichissent avec un ensemble de paradigmes permettant de créer des classifications, et d'autre part dans la famille des méthodes de l'intelligence artificielle auxquelles ils fournissent un mécanisme perceptif indépendant des idées propres de l'implémenter, et des informations d'entrée au raisonnement logique formel [13] (figure.II.2).




Figure II.2. RNB vs RNA.

### II.2.3. Apprentissage profond (Deep Learning)

Le *Deep Learning* ou apprentissage profond est un type d'intelligence artificielle dérivé du *Machine Learning* (apprentissage automatique) où la machine est capable d'apprendre par

elle-même, contrairement à la programmation où elle se contente d'exécuter à la lettre des règles prédéterminées.

Les réseaux profonds ont une méthodologie similaire à celle des méthodes traditionnelles d'apprentissage supervisé : ils reçoivent des images en entrée, détectent les *features* de chacune d'entre elles, puis entraînent un classifieur dessus [14].

Cependant, les *features* sont apprises automatiquement, contrairement aux techniques d'apprentissage supervisé. Et c'est la réside une des forces des réseaux de neurones profonds : plus besoin d'implémenter un algorithme d'extraction "à la main". Les modèles du deep learning réalisent eux-mêmes tout le boulot fastidieux d'extraction et description de *features* : lors de la phase d'entraînement, l'erreur de classification est minimisée afin d'optimiser les paramètres du classifieur et les *features*. De plus, l'architecture spécifique du réseau permet d'extraire des *features* de différentes complexités, des plus simples au plus sophistiquées.

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (big data). Aujourd'hui, les réseaux de neurones convolutifs (CNN) sont les modèles les plus performants pour la segmentation et la classification des images médicales.

### II.2.4. Les réseaux de neurones convolutifs

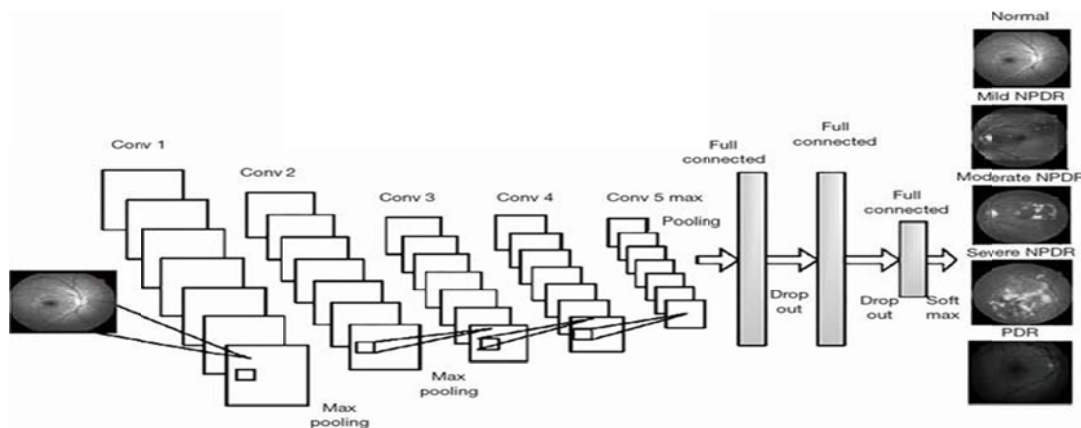
Les réseaux de neurones convolutifs (CNN, de l'anglais, Convolutional Neural Network) sont à ce jour les modèles les plus performants pour la classification, la localisation et la segmentation des images surtout dans le domaine médical. Les CNN comportent deux parties bien distinctes. En entrée, une image est fournie sous la forme d'une matrice de pixels.

Elle a 2 dimensions pour une image en niveaux de gris. La couleur est représentée par une troisième dimension, de profondeur 3 pour représenter les couleurs fondamentales [Rouge, Vert, Bleu].

La première partie d'un CNN est la partie convolutive à proprement parler. Elle fonctionne comme un extracteur de caractéristiques des images. Une image est passée à travers une succession de filtres, ou noyaux de convolution, créant de nouvelles images appelées cartes de convolutions. Certains filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local. Au final, les cartes de convolutions sont mises à plat et concaténées en un vecteur de caractéristiques, appelé code CNN [15].

Ce code CNN (figure II.3) en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie, constituée de couches entièrement connectées (perceptron multicouche). Le rôle de cette partie est de combiner les caractéristiques du code CNN pour générer la sortie.

La sortie est la dernière couche comportant un neurone par catégorie. Les valeurs numériques obtenues sont généralement normalisées entre 0 et 1, de somme 1, pour produire une distribution de probabilité sur les catégories.



**Figure II.3.** Les différentes couches pour construire un réseau neuronal convolutionnel.

### II.2.4.1. Les différentes couches des réseaux de neurones convolutifs

Il existe un grand nombre de variables d'architectures profondes. La plupart d'entre eux sont des combinaisons de certaines architectures simples afin de développer des architectures plus complexes. Une architecture CNN est formée par un empilement de couches de traitement indépendantes.

Dans cette section du chapitre, nous allons citer les couches les plus utilisées pour former un CNN :

#### A. Couche de convolution (CONV)

La couche de convolution est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche. Son but est de repérer la présence d'un ensemble de caractéristiques (features) dans les images reçues en entrée. Pour cela, un filtrage par convolution est réalisé : son principe est de faire "glisser" une fenêtre représentant la feature sur l'image, et de calculer le produit de convolution entre la feature et chaque portion de l'image balayée. Une feature est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte.

La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux features que l'on souhaite retrouver dans les images.

Nous obtenons pour chaque paire (image, filtre) une carte d'activation, ou feature map, qui nous indique où se situent les features dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la feature [16].

Trois hyper paramètres permettent de dimensionner le volume de la couche de convolution : **la profondeur de la couche** (nombre de noyaux de convolution), **le pas** (contrôle le chevauchement des champs récepteurs) et **la marge** (est le troisième hyper paramètre, permet de contrôler la dimension spatiale du volume de sortie.).

### B. Couche de pooling (POOL)

Un autre concept important des CNN est le pooling, ce qui est une forme de sous échantillonnage de l'image. L'image d'entrée est découpée en une série de rectangles de  $n$  pixels de côté qui ne se chevauchent pas (pooling). Le pooling réduit la taille spatiale d'une image intermédiaire, réduisant ainsi la quantité de paramètres et de calcul dans le réseau. Il est donc fréquent d'insérer périodiquement une couche de pooling entre deux couches convolutives successives d'une architecture CNN pour contrôler l'overfitting (sur-apprentissage). L'opération de pooling crée aussi une forme d'invariance par translation. La couche de pooling fonctionne indépendamment sur chaque tranche de profondeur de l'entrée et la redimensionne uniquement au niveau de la surface. La forme la plus courante est une couche de mise en commun avec des fenêtres de taille  $2 \times 2$  (largeur/hauteur) et comme valeur de sortie la valeur maximale en entrée. On parle dans ce cas de « Max-Pool  $2 \times 2$  » (figure.II.4).

Il est possible d'utiliser d'autres fonctions de pooling que le maximum. Nous pouvons utiliser un average pooling (la sortie est la moyenne des valeurs de l'entrée), Dans les faits, même si initialement l'average pooling était souvent utilisé il s'est avéré que le max-pooling était plus efficace car celui-ci augmente plus significativement l'importance des activations fortes. En d'autres circonstances, nous pourrions utiliser un pooling stochastique.

Le pooling permet de gros gains en puissance de calcul. Cependant, en raison de la réduction agressive de la taille de la représentation (et donc de la perte d'information associée), la tendance actuelle est d'utiliser de petits filtres (de taille  $2 \times 2$  ou  $3 \times 3$ ). Il est aussi possible d'éviter la couche de pooling mais cela implique un risque sur-apprentissage plus important [17].




Figure II.4. Max Pooling avec un filtre de taille 2x2 et un pas de 2.

### C. Couche de correction (ReLU)

Afin d'améliorer l'efficacité du traitement, il est possible d'insérer entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie. Cette couche est la fonction ReLU (Rectified Linear Units), cette dernière remplace toutes les valeurs négatives reçues en entrées par des zéros (figure.II.5).

Cette fonction, appelée aussi « fonction d'activation non saturante », elle augmente les propriétés non linéaires de la fonction de décision et de l'ensemble du réseau sans affecter les champs récepteurs de la couche de convolution.

Souvent, la correction ReLU est préférable, car il en résulte la formation de réseau neuronal plusieurs fois plus rapide, sans faire une différence significative à la généralisation de précision [17].




Figure II.5. Allure de la fonction d'activation ReLU.

### D. Couche entièrement connectée (FC)

La couche entièrement connectée (Fully Connected FC) constitue généralement la dernière couche d'un réseau de neurones convolutif ou non, donc elle n'est pas caractéristique d'un CNN.

Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs



## CHAPITRE II: Deep Learning

reçues en entrée. Elle permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille NN, où NN est le nombre de classes dans le problème de classification d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe.

Chaque valeur du tableau en entrée "vote" en faveur d'une classe. Les votes n'ont pas tous la même importance : la couche leur accorde des poids qui dépendent de l'élément du tableau et de la classe. Pour calculer les probabilités, la couche fully-connected multiplie donc chaque élément en entrée par un poids, fait la somme, puis applique une fonction d'activation (Soft max).

Ce traitement revient à multiplier le vecteur en entrée par la matrice contenant les poids. Le fait que chaque valeur en entrée soit connectée avec toutes les valeurs en sortie explique le terme fully-connected [18].

### **E.Couche de dé-convolution**

La couche déconvolutionnelle (couche de convolution transposée) inverse le fonctionnement d'une couche convolutionnelle standard afin de récupérer la taille de l'entrée d'origine. La couche convolutionnelle transposée est similaire à la couche déconvolutionnelle en ce sens que la dimension spatiale générée par les deux est la même. Donc, elle n'inverse pas la convolution standard par des valeurs, mais uniquement par des dimensions. Cette couche est utilisée dans le cas de la segmentation des images [18].

### **F.Couche de perte (LOSS)**

La couche de perte spécifie comment l'entraînement du réseau pénalise l'écart entre le signal prévu et le signal réel. Elle est la dernière couche dans un réseau de neurones. Diverses fonctions de perte adaptées à différentes tâches peuvent y être utilisées. La perte « Soft max » est la plus utilisée pour prédire une seule classe parmi K classes mutuellement exclusives. La perte euclidienne est utilisée pour régresser vers des valeurs réelles [18].

### **G.Couche de normalisation**

La normalisation est une technique d'entraînement de réseaux de neurones très profonds qui standardise les entrées d'une couche pour chaque mini-lot. Cela a pour effet de stabiliser le processus d'apprentissage et de réduire considérablement le nombre d'époques de formation nécessaires pour former des réseaux profonds [19].

### **H. Couche de régularisation (Drop out)**

## CHAPITRE II: Deep Learning

Entre chaque couche dense, il est commun d'utiliser une couche dropout. C'est une technique de régularisation (pour combattre l'over-fitting) dont le principe est de désactiver aléatoirement à chaque itération un certain pourcentage des neurones d'une couche. Cela évite ainsi la sur-spécialisation d'un neurone (et donc l'apprentissage par cœur) [20].

### II.2.4.2. Avantages des CNN

Les réseaux de neurones convolutifs utilisent relativement peu de prétraitements. Cela signifie que le réseau est responsable de faire évoluer tout seul ses propres filtres (apprentissage sans supervision), ce qui n'est pas le cas d'autres algorithmes plus traditionnels. On outre, L'absence de paramétrage initial et d'intervention humaine est un atout majeur des CNN [21].

### II.2.4.3. Inconvénients des CNN

Parmi les inconvénients d'utiliser les CNN, nous citons [22] :

1. Nécessite une grande base de données (minimum 2500 images), cette exigence en matière de données entraînant un sur-apprentissage et un sous-apprentissage (overfitting et underfitting).
2. Exigences de matériel puissant en terme de capacité de mémoire et carte graphique (GPU).
3. Apprentissage non expressif.
4. Calcul coûteux (Temps d'apprentissage important).

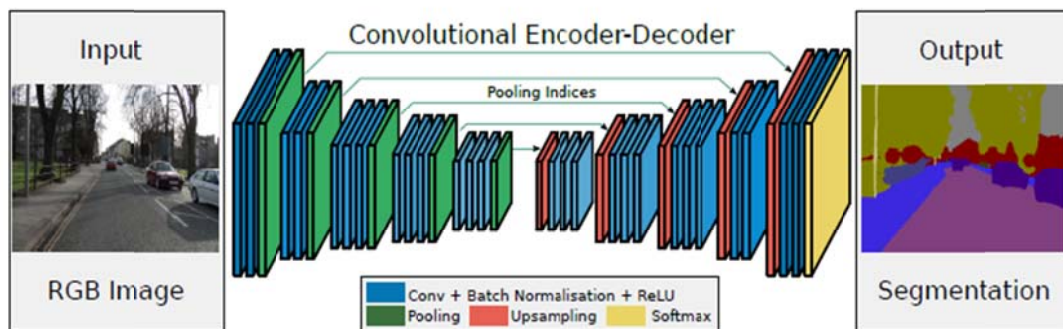
Dans la section suivante du chapitre, nous présentons le principe des modèles de segmentation par Deep Learning les plus utilisés dans la littérature.

## II.3. Architectures du Deep Learning

### II.3.1. SegNet

Le modèle SegNet présente un équilibre satisfaisant entre précision de la classification et temps de calcul. L'architecture de SegNet est symétrique et permet de replacer précisément les caractéristiques abstraites aux bonnes localisations spatiales. Le SegNet présente une architecture encodeur-décodeur conçue sur la base des couches de convolution du modèle VGG-16 (se compose de 16 couches convolutives et est très attrayant en raison de son architecture très uniforme). L'encodeur est une succession de couches convolutives suivies par une couche de normalisation par batch (BN) et des fonctions de transfert non linéaires (ReLU). Chaque bloc de 2 ou 3 convolutions est suivi par une couche de max pooling de taille 2x2 et un pas de 2, cette

partie sert à extraire les cartes des caractéristiques. La partie décodeur est une symétrie de l'encodeur et possède le même nombre de convolutions et le même nombre de blocs afin d'extraire les images finales (figure.II.6) [23].



**Figure II.6.** L'architecture SegNet.

### II.3.2.UNet

UNet est un modèle issu du réseau de neurone convolutif traditionnel développé pour la segmentation des images biomédicales. Il permet la localisation et la segmentation en effectuant la classification sur chaque pixel, de sorte que l'entrée et la sortie partagent la même taille. Ce modèle fameux de la forme U (figure II.7) est symétrique et se compose de deux parties principales :

-**La partie gauche** est appelée chemin de contraction, qui est constitué par le processus convolutif général : constituée de nombreux blocs de contraction. Chaque bloc prend une entrée applique deux couches de convolution 3x3 suivies d'une fonction ReLU et d'un max pooling 2x2. Le nombre de filtres ou de mappages de caractéristiques après chaque bloc double afin que l'architecture puisse apprendre efficacement les structures complexes.

-**La partie droite** est un chemin expansif, qui est constitué de couches convolutives 2d transposées (Le nombre de blocs d'expansion est identique au nombre de blocs de contraction). L'architecture Unet est capable de localiser l'image en prédisant l'image pixel par pixel [24].




Figure II.7. Architecture U-Net.

### II.3.3. Réseaux de neurones entièrement connectés (FCN)

Les réseaux de neurones entièrement connectés (FCN) sont un outil particulièrement efficace pour la segmentation sémantique pour de nombreux types d'images, en transformant la classification par image en classification par pixel. FCN un type de réseau de neurones artificiels similaire aux modèles VGG et AlexNet, dont l'architecture est telle que tous les nœuds, ou neurones, d'une couche sont connectés aux neurones de la couche suivante. En pratique ce type de réseau présente quelques problèmes en termes de segmentation d'images, produisant un effet de flou au niveau des frontières. De tels réseaux sont intenses en termes de calcul et peuvent être sujets au sur apprentissage (figure.II.8) [23].

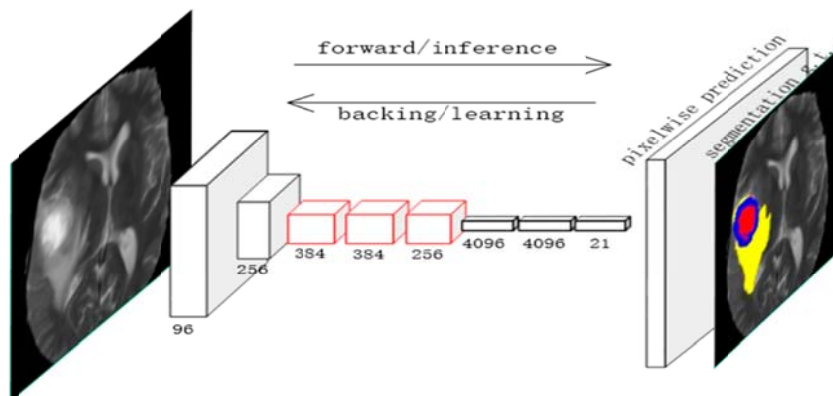


Figure II.8. FCN.

### II.4. Les options d'apprentissage

Afin d'optimiser les poids d'un CNN pendant la partie d'apprentissage, plusieurs paramètres importants peuvent être utilisés :

### II.4.1. Optimiseurs

- **Adam (adaptive moment estimation)** : l'optimiseur Adam comprend les informations sur le taux d'apprentissage, le facteur de régularisation L2 et la taille du mini-batch size.
- **SGDM (stochastic gradient descent with momentum)** : Option de formation pour la descente de gradient stochastique avec moment, il comprend les informations de taux d'apprentissage, le facteur de régularisation L2 et la taille du mini-batch size [25].

### II.4.2. Epoque

- **Epoch** : (numéro d'époque) correspond à un passage complet des données.
- **MaxEpochs** : nombre maximal d'époques à utiliser pour l'apprentissage [26].

### II.4.3. Taux d'apprentissage

- **InitialLearnRate** : Taux d'apprentissage initial utilisé pour l'entraînement, spécifié comme la paire séparée par des virgules composées de « InitialLearnRate » et d'un scalaire positif. La valeur par défaut est 0,001 pour l'optimiseur 'Adam'. Si le taux d'apprentissage est trop faible, l'entraînement prend du temps.
- **LearnRateSchedule** : Option pour réduire le taux d'apprentissage pendant l'entraînement, spécifiée comme la paire séparée par des virgules composées de 'LearnRateSchedule' et de l'un des éléments suivants :

« None » : Le taux d'apprentissage reste constant tout au long de l'entraînement.

« Piecewise » : Le logiciel met à jour le taux d'apprentissage après certain nombre d'époques en multipliant par un certain facteur.

- **LearnRateDropPeriod** : Nombre d'époques pour l'abandon du taux d'apprentissage, spécifié le nombre d'époques entre les multiplications. Cette option n'est valide que lorsque la valeur de LearnRateSchedule est « Piecewise ».
- **LearnRateDropFactor** : Facteur d'abandon du taux d'apprentissage, spécifié la valeur de facteur de multiplication. Cette option n'est valide que lorsque la valeur de LearnRateSchedule est « Piecewise » [26].

### II.4.4 Fréquence de validation (ValidationFrequency)

Fréquence de validation du réseau en nombre d'itérations, spécifiée sous la forme d'un entier positif. La valeur `ValidationFrequency` est le nombre d'itérations entre les évaluations des métriques de validation [26].

### II.4.5 MiniBatchSize

Est un paramètre pertinent pour créer un sous-ensemble de l'ensemble d'apprentissage utilisé pour évaluer le gradient de la fonction de perte et mettre à jour les pondérations [26].

### II.4.6 Ressource matérielle

L'environnement d'exécution (`ExecutionEnvironment`) : Ressource matérielle pour l'entraînement du réseau : 'CPU', 'GPU', 'Multi-GPU' et 'Multi-CPU'.

- **CPU** : est le processeur central de l'ordinateur, son acronyme signifie unité de traitement principal. Le CPU est chargé d'effectuer toutes sortes de calculs. Il est capable de mener de nombreuses tâches différentes [27].
- **GPU** : désigne le processeur qui équipe la carte graphique, son acronyme signifie unité de traitement graphique. Le GPU gère uniquement les calculs graphiques. Il s'occupe de l'affichage des pixels, textures et formes à l'écran, ainsi que du traitement de la vidéo [27].

L'entraînement avec un GPU est beaucoup plus rapide qu'un CPU

## II.5 Etat de l'art

Dans la section suivante, nous présentons les différentes approches reportées dans la littérature pour la détection du réseau vasculaire basé sur l'apprentissage profond.

**Wang et al [28]** ont proposé une technique qui combine deux classificateurs, un réseau de neurones convolutif (CNN) a été utilisé pour extraire l'ensemble des caractéristiques et les forêts aléatoires (Random Forest RF) pour la segmentation des vaisseaux rétiniens (figure II.9). Pour la partie prétraitement, initialement le canal vert a été extrait de l'image d'origine, puis l'image a été débruitée par le filtre gaussien suivie d'une amélioration du contraste à l'aide de l'égalisation d'histogramme. Ensuite, une sélection d'échantillons basée sur des supers pixels, cette méthode a été utilisée pour capturer la redondance des données. Comme option d'apprentissage ils ont utilisé 100 époques. Ils ont obtenu une précision moyenne et une AUC de 0.9813 et 0.9751 pour la base STARE et 0.9767 et 0.9475 pour la base DRIVE, respectivement.

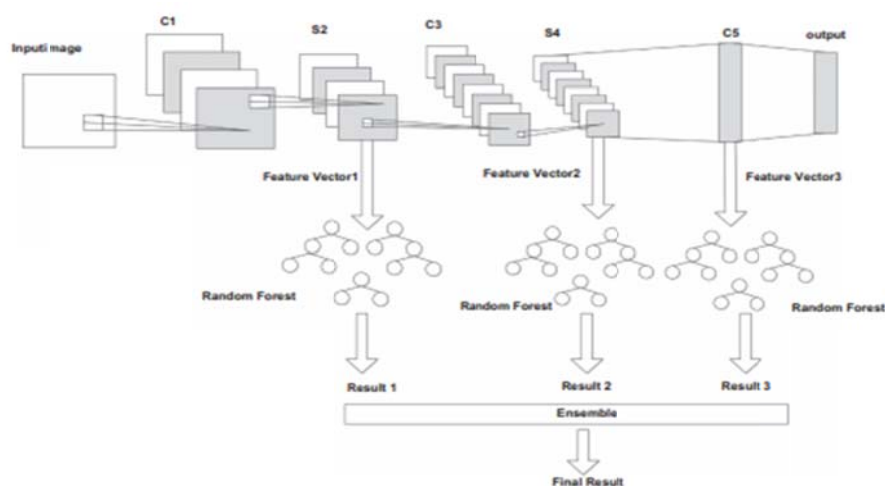


Figure II.9. L'architecture proposée par Wang et al [28].

**P. Liskowski et al [29]** ont proposé une technique basée sur un réseau de neurones formé sur un large nombre d'images. L'architecture est composée de trois couche de convolution avec des filtres de taille 3x3 et un pas de 1, une couche de pooling de taille 2x2 avec un pas de 2 et deux couche entièrement connectées (FC) (figure II.10). Ce modèle a été formé en utilisant toutes les images d'entraînement sur l'ensemble des images de la base de données DRIVE et 19 images ont été choisies à partir de la base d'image STARE en suivant une stratégie de suppression. Le reste des images ont été utilisées pour les tests. La méthode a atteint une précision moyenne et une AUC de 0.9667, 0.9930 pour la base STARE et 0. 9507, 0.9787 pour la base DRIVE. Cette méthode n'a pas donné des bons résultats pour les petits vaisseaux.


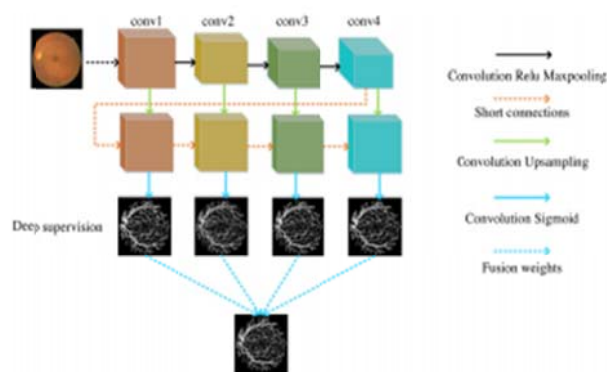


Figure II.10. L'architecture proposée par P. Liskowski et al [29].


**Song Guo et al [30]** ont présenté une technique multi-échelle utilisant un apprentissage supervisé profond avec un réseau de courte connexion (BTS-DSN) pour la segmentation des vaisseaux

sanguins. Dans ce réseau de neurones profonds, des informations sémantiques de bas niveau sont transmises à haut niveau en utilisant les connexions courtes de bas en haut pour affiner les résultats en sorties secondaires de haut niveau et toutes les informations de structure ont passées au niveau bas par une connexion court de haut en bas. Cette technique réduit le bruit dans les sorties latérales de bas niveau (figure II.11). Pour la partie augmentation de la base, mise à l'échelle, retournement et la rotation ont été utilisés. Ce travail a été évalué sur les bases d'images DRIVE et STARE et a donné une précision moyenne de 0.9674 et une AUC de 0.9859 pour la base STARE et 0.9561, 0.9806 pour la base DRIVE, respectivement.



**Figure II.11.** L'architecture proposée BTS-DSN par Song Guo et al [30].

**Juntang Zhuang [31]** a recommandé un cadre de filet d'échelle qui est une chaîne des U-nets récurrents pour la segmentation du réseau rétinien. Ce LadderNet a de nombreuses paires d'encodeur-décodeur branches (figure II.12). LadderNet a plus de chemins pour le flux d'informations en raison du saut de connexions et les blocs résiduels. Il est observé comme une combinaison de réseaux. La méthode atteint une précision moyenne et une AUC de 0.9656 et 0.9839, respectivement.





**Figure II.12.** L'architecture proposée par Juntang Zhuang [31].

**Martina Melinscak et al [32]** ont proposé un cas de classification binaire : pour chaque pixel ont considéré deux classes possibles (vaisseaux ou non-vaisseaux). Ils ont utilisé un CNN formé d'une succession de couches de convolution (C) et de max pooling (MP) (tableau II.1), implémenté sur un GPU pour segmenter les vaisseaux sanguins. La méthode a atteint une précision moyenne et une AUC de 0,9466 et 0,9749 pour la base DRIVE, respectivement.

Layer	Type	Maps and neurons	Filter size	Weights	Connections
0	I	1M x 65x65N	—	—	—
1	C	48Mx60x60N	6x6	1776	6393600
2	MP	48Mx30x30N	2x2	—	—
3	C	48Mx26x26N	5x5	57648	38970048
4	MP	48Mx13x13N	2x2	—	—
5	C	48Mx10x10N	4x4	36912	3691200
6	MP	48Mx5x5N	2x2	—	—
7	C	48Mx4x4N	2x2	9264	148224
8	MP	48Mx2x2N	2x2	—	—
9	FC	100N	1x1	19300	19300
10	FC	2N	1x1	202	202

**Tableau II.1.** L'architecture proposée par Martina Melinscak [32].

## II.6.Conclusion

Dans ce chapitre nous avons défini quelque notion de base concernant le Deep Learning et les Réseaux de Neurones Convolutifs, puis une brève description des modèles de segmentation sémantique les plus utilisés. Finalement, nous avons présenté quelques travaux existants dans la littérature pour la détection du réseau vasculaire basés sur les méthodes de Deep Learning.

Dans le chapitre suivant nous présenterons les architectures proposés pour la segmentation sémantique du réseau rétinien, ainsi que les résultats obtenus.

# **CHAPITRE III: Expérimentation, Résultats et Discussions**

### III.1. Introduction

La segmentation d'images est une procédure importante dans de nombreux systèmes de diagnostic médical. Elle contribue au diagnostic de plusieurs pathologies rétiniennes, telles que la rétinopathie diabétique RD, la dégénérescence maculaire liée à l'âge DMLA, le glaucome...etc. Au cours de ces dernières années, la gamme d'utilisation des images du fond d'œil pour la détection et l'analyse des pathologies est de plus en plus large. En observant les changements des vaisseaux, des lésions rétiniennes peuvent être trouvées. Par exemple, si un micro-anévrisme apparaît dans le fond de l'œil, il indique une grande possibilité d'atteindre le diabète. Si quelqu'un a une artériosclérose rétinienne, il peut y avoir un risque élevé d'hypertension. La progression de la RD provoque des tortuosités et des changements de diamètre dans le réseau rétinien et donne naissance à des néo-vaisseaux. Par conséquent, la segmentation du réseau vasculaire est une tâche importante pour la détection précoce de la RD. Comme la structure de l'arbre vasculaire est caractéristique du patient, elle ne change pas ou très peu au cours d'une rétinopathie, cela privilège l'usage des vaisseaux pour le recalage des images rétiniennes prises à des moments différents (détection des points de bifurcation). En outre, l'arbre vasculaire est considérée comme le premier élément dans l'œil qui permet de se repérer, la papille peut être définie comme son origine et la macula par son absence. Par conséquent, les informations des images du fond d'œil jouent un rôle important dans la découverte précoce d'une maladie.

La rétine représente un motif unique pour chaque individu, ceci permet de développer des environnements plus sûrs, où il est difficile ou impossible de créer une copie des propriétés utilisées par le système pour discriminer entre des individus autorisés et imposteurs. Dans ce contexte, la rétine apparaît comme une très intéressante caractéristique biométrique.

Les images rétiniennes contiennent des informations locales et temporelles de la rétine, c'est-à-dire qu'une image de fond ne contient qu'une partie des informations de l'ensemble du fond. Récemment et grâce à l'Intelligence Artificielles, elles sont utilisées même pour la prédiction des maladies cardiaques.

Le chapitre trois donne plus de détails sur les algorithmes de segmentation du réseau rétinien par la méthode de deep learning et les étapes qu'il faut respecter pour parvenir à des résultats satisfaisants.

Le présent chapitre est structuré comme suit : dans la première section, les ressources matérielles, le logiciel utilisé ainsi que les bases de données utilisées sont décrites. Dans la deuxième section, nous détaillerons les approches envisagées pour la détection des petits et les

gros vaisseaux rétiniens. Pour cela, nous proposons trois architectures différentes, à savoir : le SegNet ; U-Net et le CNN. La section trois est consacrée à la présentation des résultats obtenus. Dans la section quatre, une évaluation des performances des méthodes proposées suivie d'une comparaison de nos résultats avec ceux obtenus dans la littérature seront présentés. Nous terminerons ce chapitre par une conclusion.


### III.2. Description de la base de données

La disponibilité de bases de données d'images accessibles au public est un facteur clé qui soutient le développement de stratégies d'extraction du réseau vasculaire rétinien.

Dans la section suivante nous présentons une brève description des bases de données utilisées dans ce travail.

#### III.2.1. Base d'images « DRIVE »

La base d'image Drive comprend 40 images couleur du fond d'œil, dont 7 images présentent des pathologies. Les images sont acquises avec un rétinographe non mydriatique Canon RC5 avec un champ de vision de 45 degré (FOV). Elles sont enregistrées au format tif, avec une taille de 768 \*584 pixels. La base d'image est divisée en deux ensembles (20 images pour l'apprentissage et 20 pour le test). La segmentation manuelle du réseau vasculaire est effectuée par deux ophtalmologues expérimentés. Un exemple d'image de la base de données DRIVE est montré dans la figure III.1 [33].



**Figure III.1.** Exemple de la base DRIVE.

#### III.2.2. Base d'images « HRF »

La base d'image HRF (High Resolution Fundus) comprend 45 images du fond d'œil en couleurs dont 15 images normales, 15 images glaucomateuses et 15 images de rétinopathie diabétique. Les images sont acquises avec un rétinographe non mydriatique avec un champ de vision de 45 degré

## Conclusion générale

Aujourd'hui, la pratique d'ophtalmologie est un outil puissant permettant l'étude de la structure et de fonctionnement des yeux et de ses annexes grâce aux multiples techniques d'acquisition d'images, parmi ces techniques, nous avons basé sur la rétinographie qui est un examen nécessaire pour la détection de plusieurs pathologies comme la rétinopathie diabétique, le glaucome...etc.

La segmentation des images médicales reste un champ de recherche très large. Dans le domaine de l'imagerie ophtalmologique, l'intérêt de la segmentation des images du fond d'œil est en effet multiple : aide au diagnostic, suivi de l'évolution de l'état du patient et l'action thérapeutique, test clinique...etc.

L'objectif de notre travail est consacré à la segmentation sémantique du réseau rétinien, à partir des images rétiniennes couleurs en utilisant des réseaux de neurones profonds (deep learning) qui ont montré ses performances ces dernières années surtout dans le domaine médical.

Dans ce projet de fin d'étude, nous avons utilisé trois architectures du deep learning différentes : SegNet, U-Net et un réseau de neurones convolutif (CNN) simple, pour la segmentation de l'arbre vasculaire rétinien en utilisant MATLAB 2019b.

Dans la phase d'entraînement, l'utilisation d'un CPU fait que le temps d'exécution soit trop coûteux. Afin de résoudre ce problème, il est nécessaire d'utiliser des réseaux de neurones convolutionnels profonds déployés sur un GPU au lieu d'un CPU.

Pour réaliser ce travail, nous avons utilisé trois bases de données publiques annotées DRIVE, HRF et CHASE\_DB1, pour faire apprendre les modèles proposés et effectué la partie validations et test.

Les paramètres du réseau sont difficiles à définir a priori. C'est pour cette raison que nous avons utilisé différents modèles avec des architectures différentes afin d'obtenir des meilleurs résultats en terme de précision et d'erreur. Ainsi, le bon choix des options d'apprentissage influe sur la performance du modèle.

Les résultats obtenus sont satisfaisants et encourageants et montrent que l'architecture SegNet a donné les meilleurs résultats par rapport à U-Net et CNN avec une précision supérieure à 96% pour les trois bases DRIVE, HRF et CHASE\_DB1, respectivement.

## Conclusion générale

Enfin, nous pouvons conclure que l'utilisation des méthodes de segmentation sémantique (deep learning) permet de donner des meilleurs résultats de segmentation par rapport aux d'autres méthodes.

### **Perspectives :**

Plusieurs perspectives peuvent être envisagées dans la prolongation de ce travail, nous pouvons citer :

- Tester nos méthodes sur d'autres bases de données plus grandes.
- Utiliser des architectures plus profondes.
- Développer des architectures permettant l'extraction des petits vaisseaux avec une grande précision.
- Développer un système pour la détection des pathologies oculaires à partir du réseau rétinien segmenté.

## Bibliographie

- [1] [Gabrielle Bonnet, Gilles Furelaud](https://planet-vie.ens.fr/thematiques/animaux/systeme-nerveux-et-systeme-hormonal/l-oeil-structure-origine-et-proprietes), "L'œil : structure, origine et propriétés physiques", Publié le 15.01.04, ["https://planet-vie.ens.fr/thematiques/animaux/systeme-nerveux-et-systeme-hormonal/l-oeil-structure-origine-et-proprietes"](https://planet-vie.ens.fr/thematiques/animaux/systeme-nerveux-et-systeme-hormonal/l-oeil-structure-origine-et-proprietes)re-origine-et-proprietes.
- [2] Sight Savers, "The structure of the human eye", Accessed, August, 2006, from website: ["http://www.sightwavers.or.uk/html/eyeconditions/huma\\_eye\\_detailed.html"](http://www.sightwavers.or.uk/html/eyeconditions/huma_eye_detailed.html)/[huma\\_eye\\_detailed.html](http://www.sightwavers.or.uk/html/eyeconditions/huma_eye_detailed.html)
- [3] Haïba Lekhal et Per Einar Ellefsen, "La perception des couleurs par l'œil", 2001-2002 <https://www.bioinformatics.org/oeil-couleur/dossier/anatomie..>
- [4] article "Éducation thérapeutique et patient expert" magazine "équilibre" n°336 page 41 Publié le juillet 2020 ["https://diabetelab.federationdesdiabetiques.org/"](https://diabetelab.federationdesdiabetiques.org/)[ationdesdiabetiques.org/](https://diabetelab.federationdesdiabetiques.org/)
- [5] FEROUÏ AMEL, "Traitement automatique d'image du fond d'œil : application au recalage des images rétiniennes", diplôme de magister en électronique biomédicale, juin 2009.
- [6] Pr Nicolas LEVEZIEL, professeur des universités, praticien hospitalier, chef de service : rétine médicale et chirurgicale, cataracte. ["https://www.chu-poitiers.fr/specialites/ophtalmologie/maladie-de-loeil/"](https://www.chu-poitiers.fr/specialites/ophtalmologie/maladie-de-loeil/)[/specialites/ophtalmologie/maladie-de-loeil/](https://www.chu-poitiers.fr/specialites/ophtalmologie/maladie-de-loeil/)
- [7] Interprétation des photographies du fond d'œil, à la suite d'une rétinographie avec ou sans mydriase [archive], Haute Autorité de santé, 11 juillet 2007, le 24 décembre 2019. ["https://fr.wikipedia.org/wiki/Fond\\_d%27%C5%93il"](https://fr.wikipedia.org/wiki/Fond_d%27%C5%93il)["https://fr.wikipedia.org/wiki/Fond\\_d%27%C5%93il"](https://fr.wikipedia.org/wiki/Fond_d%27%C5%93il)[3il](https://fr.wikipedia.org/wiki/Fond_d%27%C5%93il)
- [8] Itebeddine Ghorbel et al ; "Segmentation des couches rétiniennes dans des images OCT : méthode et évaluation quantitative", MajecSTIC, 2009.
- [9] Dr Olivier LICHTWITZ, chef de clinique, "chirurgie réfractive, cataracte, greffe de cornée glaucome : équipements et innovations médicales". <http://www.chu-poitiers.fr/specialites/ophtalmologie/equipements-et-innovations-medicales/>
- [10] "DataScientest courses interactifs", octobre 2015. <https://datascientest.com/deep-learning-reseau-de-neurones-biologiques-ou-artificiels>
- [11] Bastien L, " les réseaux de neurones artificiels", Le " BigData" : magazine Intelligence artificiel et cloud bigdata, le 5 avril 2019. <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>

## Bibliographie

[12] Commission d'enrichissement de la langue française, « Vocabulaire de l'intelligence artificielle (liste de termes, expressions et définitions adoptés) », Journal officiel de la République française no 0285 du 9 décembre 2018.

[https://fr.wikipedia.org/wiki/R%C3%A9seau\\_de\\_neurones\\_artificiels](https://fr.wikipedia.org/wiki/R%C3%A9seau_de_neurones_artificiels)

[13] Pascal Monasse, "Qu'est-ce qu'un réseau de neurones convolutif (ou CNN)", OpenClassRooms: magazine article, Mis à jour le 05/05/2020.

["https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees%20visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn"](https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees%20visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn)

[14] Boughaba Mohammed et Boukhris Brahim, "L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu", Université Kasdi Merbah OUARGLA, 2016-2017.

[15] Mokri Mohammed Zakaria, "Classification des images avec les réseaux de neurones Convolutionnels", Université Abou Bakr Belkaïd Tlemcen, le 03/07/2017.

[16] Graham, Benjamin, "Fractional Max-Pooling", Dept of Statistics, University of Warwick. 13/05/2015.

[17] Kimia Nadjahi, "Découvrez les différentes couches d'un CNN", "OpenClassRooms ": magazine Article, Mis à jour le 05/05/2021.

<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des%20donneesvisuelles/5083336-decouvrez-les-differentes-couches-dun>

[18] Fully Convolutional Networks for Semantic Segmentation “, le 14 Nov 2014.

["https://arxiv.org/search/cs?searchtype=author&query=Shelhamer%2C+E"Shelhamer,Trevor Darrell](https://arxiv.org/search/cs?searchtype=author&query=Shelhamer%2C+E%22Shelhamer,Trevor Darrell) “.

[19] Jason Brownlee, "la-couche-convolutive-transposée-Article", SiteWeb "Machine Learning, aout 2019.

["https://machinelearningmastery.com/batch-normalization-for-training-of-deep%20neuralnetworks/"](https://machinelearningmastery.com/batch-normalization-for-training-of-deep%20neuralnetworks/)

[20] Ricco Rakotomalala “deep learning –Perceptrons simples et multicouches–” Université Lumière lyon 2”, avril 2016.

[21] Patrick le callet, christian viard-gaudin et dominique barba, "A convolutional Neural Network Approach for objective video Quality Assessment [en ligne] ", Octobre 2006.

[22] SiteWeb "OpenGenus"Disadvantages of CNN models article "Priyanshi Sharma mars 2019

["https://www.researchgate.net/post/What is the pros and cons of Convolutional neura"](https://www.researchgate.net/post/What_is_the_pros_and_cons_of_Convolutional_neura)  
[post/What is the pros and cons of Convolutional neura](https://www.researchgate.net/post/What_is_the_pros_and_cons_of_Convolutional_neura)



## Bibliographie

- [23] Siddharth das, "CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more...", Medium magazine, le Nov 16, 2017.  
<https://medium.com/analytics-vidhya/cnns-architectures-lenet-alexnet-vgg-googlenetresnet-and-more-666091488df5>
- [24] Heet Sanksara, "UNet Introducing Symmetry in Segmentation", TowardsDataScience, 23/01/2019.  
<https://towardsdatascience.com/u-net-b229b32b4a71>.
- [25] Aegeus Zerium, " Demystifying Convolutional Neural Networks", Medium magazine, 2 sep 2018.  
<https://medium.com/@eternalzerodayx/demystifying-convolutional-neural-networks-ca17bdc75559>
- [26] "<https://ch.mathworks.com/help/deeplearning/ref/nnet.cnn.trainingoptionsadam> Consulté le 15-04-2021.
- [27] "<https://www.01net.com/actualites/quelle-est-la-difference-entre-cpu-et-gpu-523253.html>" le 28/10/2010.
- [28] S. WANG, Y. YIN, G. CAO, B. WEI, Y. ZHENG, G. YANG, "Hierarchical retinal blood vessel segmentation based on feature and ensemble learning", Neurocomputing, 149 (2015), pp. 708–717.
- [29] P. LISKOWSKI, K. KRAWIEC, "Segmenting retinal blood vessels with deep neural networks", IEEE Trans. Med. Imaging, 35(11) (2016), pp. 2369–2380.
- [30] S. GUO, K. WANG, H. KANG, Y. ZHANG, Y. GAO, T. LI, "BTS-DSN: Deeply supervised neural network with short connections for retinal vessel segmentation", International Journal of Medical Informatics, 126(11) (2019), pp. 105–113.
- [31] J. ZHUANG, "LadderNet: Multi-path networks based on U-Net for medical image segmentation", arXiv:1810.07810, 2015.
- [32] Martina Melinscak, Pavle Prentasic and Sven Loncaric, "Retinal Vessel Segmentation Using Deep Neural Network", The university of Zagreb .Croatia, 2018.
- [33] J. J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. van Ginneken, "Digital Retinal Image for Vessel Extraction (DRIVE) Database", Image Sciences Institute, University Medical Center Utrecht, 2004. "<http://www.isi.uu.nl/Research/Databases/DRIVE/>"RIVE/.
- [34] Attila Budai, Joachim Hornegger, Georg Michelson, "Multiscale Approach for Blood Vessel Segmentation on Retinal Fundus Images", In Invest Ophthalmol Vis Sci 2009.
- [35] M. M. Fraz ,P. Remagnin , A. Hoppe , B. Uyyanonvar , A. R. Rudnicka , C. G. Owen, S. A. Barman, "An Ensemble Classification-Based Approach Applied to Retinal Blood Vessel

Segmentation", IEEE Transactions on Biomedical Engineering, volume 59, 2012, <https://www.idiap.ch/software/bob/docs/bob/bob.db.chasedb1/master/index>.

[36] A. OLIVEIRA, S. PEREIRA, C. A. SILVA, "Retinal vessel segmentation based on Fully Convolutional Neural Networks", Applications, 112(1) (2018), pp. 149–162.

[37] Pearl Mary Samuel and Thanikaiselvan Veeramalai, "Multilevel and Multiscale Deep Neural Network for Retinal Blood Vessel Segmentation", Symmetry, School of Electronics Engineering, Vellore Institute of Technology, Vellore 632014, India Received: 21 May 2019; Accepted: 17 July 2019; Published: 22 July 2019).