

N° Ordre...../DISM/FT/UMBB/2022

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE.

UNIVERSITE M'HAMED BOUGARA-BOUMERDES



Faculté de Technologie  
Département Ingénierie des Systèmes Electriques

**Mémoire de Master**

Présenté par  
BARNOR Benedicta

NAKYEYUNE Susan

**Filière : Génie Biomédical**  
**Spécialité : Instrumentation Biomédicale**

**THÈME**

---

*Détection Automatique des coupes  
Echographiques Fœtales*

---

**Soutenu publiquement le 30 /06 /2022 devant le jury composé de :**

Dr Belkacem Samia	MCA	UMBB	Président
Dr. Messaoudi Nouredine	MCA	UMBB	Examinateur
Dr. Ammar Mohammed	MCA	UMBB	Rapporteur
Dr Benamer Lamia Nawel	MCA	EPH Kouba	Co-rapporteur

**Année Universitaire : 2021/2022**

## **Remerciements**

Ce travail ne serait pas ce qu'il est sans ces peuples alors

Nous rendons la grâce en premier lieu à l'Eternel Dieu tout puissant et plus aimant de nous avoir donné la vie et la sante d'arriver à ce jour et nous a accorder la force et la volonté pour ce travail.

Nous tenons à remercier Dr Belkacem Samia d'avoir accepté de présider ce jury. Aussi, à remercier Dr. Messaoudi Noureddine, Dr. Ammar Mohammed et Dr Benamer Lamia Nawel d'avoir accepté d'être les membres de jury pour notre travail.

Un grand merci notre à notre encadreur Dr. AMMAR MOHAMMED, professeur au département ingénierie des systèmes électriques à l'Université de Boumerdès, pour son encadrement de bon qualité, ses conseils et son sacrifice afin de réaliser ce travail.

Nous remercions tous les enseignants de Génie Biomédical (GBM) pour leurs travaux dans ce niveau de notre éducation.

Nous sommes vraiment remerciant.

BARNOR Benedicta

NAKYEYUNE Susan

## **Dédicaces**

*Avec joie je dédie ce travail :*

*Avant tout, au Seigneur mon Dieu, béni soit Son Saint Nom pour le privilège de faire ce travail. Je rends grâce au Dieu Tout-Puissant qui m'a constamment fortifié et me donne la grâce d'être là où je suis aujourd'hui.*

*À ma mère bien-aimée Ayebare Constance pour m'avoir soutenu sans cesse de toutes les manières possibles, son amour, sa croyance en moi et son désir de me voir exceller ont toujours gardé mes espoirs élevés.*

*À mon cher père Ssejjoba Eddie et mon grand frère Kyeyune Edward Jr dont je désire rendre fier.*

*À la famille de Boumerdès qui a vraiment fait de mon séjour en Algérie un moment remarquable, mes remerciements à Emanuele Cardani.*

*À ma chère binôme et sœur Benedicta Barnor, merci pour votre engagement, votre travail écharné et vos encouragements tout au long de ce voyage, je suis béni d'avoir travaillé avec vous.*

*À mes collègues de l'Université, un grand merci à vous, à tous mes professeurs depuis ma licence, merci pour votre grand travail dans mes études.*

*À toutes personnes qui m'a pris cher.*

*NAKYEYUNE Susan*

## **Dédicaces**

*Gloire à Dieu pour ce travail !*

*A ma chère et jolie mère Mary T. Barnor, merci pour votre sacrifice et ton soutien qui m'amenée là où je suis aujourd'hui et va m'amener là où je serai demain. Il me manque des mots d'exprimer ma gratitude.*

*A mon oncle Benjamin Sowah et mes chers frères : Ransben, Benedict et Jesse qui sont avec moi dans toutes générosités et courages.*

*A ma famille de Boumerdès qui m'ont encouragé de persévérer et continuer ici en Algérie. Un grand merci à Pr. Emanuele Cardani et à mes très chers amis, les gens de Serious people : Lawson Marc, Amenyah Gertrude, Amoako Atta Agya Yaw et Ofosu Andrew Abedi.*

*A ma copine et binôme Nakyeyune Susan pour les sacrifices et l'effort que tu as mis dans ce travail et nos vies.*

*Aussi à mes amis de l'Université de Boumerdes.*

*Dernièrement, je dédie ce travail à moi-même.*

**BARNOR Benedicta**

## Résumé

Ce projet vise la classification des images échographiques du plan fœtal. Ceci est réalisé en examinant le CNN en profondeur et en étudiant les méthodes de classification automatisées à l'aide d'architectures conçues pour les tâches d'apprentissage en profondeur. Trois architectures CNN différentes : EfficientNetB0, ResNet50 et InceptionV3 sont entraînées sur ces images pour examiner leurs performances. Le choix final de ces architectures est basé sur le niveau du taux de classification dans la classification des images. Sur la base des performances du taux de classification, le modèle EfficientNetB0 est arrivé en tête du classement et pour améliorer ses performances de classification, nous avons utilisé le prétraitement d'augmentation des données. Les images utilisées dans l'apprentissage de ces réseaux proviennent de l'EPH Kouba et de la Clinique des Lilas.

Mots-clés : classification d'images, images échographiques du plan fœtal, CNN, EfficientNetB0, data augmentation

## Abstract

This project is aimed at the classification of fetal plane echographic images. This is achieved by looking into deep CNN and studying the automated classification methods using architectures built for Deep learning tasks. Three different CNN architectures: EfficientNetB0, ResNet50 and InceptionV3 are trained on these images to examine their performances. The final choice from these architectures are based on the accuracy level in image classification. Based on the accuracy performance, EfficientNetB0 model topped the ranking and to improve its classification performances, we have used data augmentation pre-processing. The images used in the training of these networks are from EPH Kouba and Clinique des Lilas.

Keywords: image classification, fetal plane echographic images, CNN, EfficientNetB0, data augmentation

## ملخص

يهدف هذا المشروع الى تصنيف صور التخطيط بالصدى لمستوى الجنين، تم تحقيق هذا المشروع من خلال فحص عميق للـ CNN. ودراسة طرق التصنيف الآلية باستخدام البنية المصممة لمهام التعلم العميق. ثلاث هياكل مختلفة للـ CNN: EfficientNetB0، ResNet50 و InceptionV3 تم تدريبها على اختبار هذه الصور من اجل فحص أدائها.

يتم الاختيار النهائي لهذه البنية حسب مستوى الدقة في تصنيف الصور وبناءا على هذا المستوى، يتصدر النموذج EfficientNetB0 الترتيب من اجل تحسين أداء التصنيف. استخدمنا المعالجة المسبقة لزيادة البيانات.

الصور المستخدمة في تدريب هذه الشبكات تعود الى مستشفى القبة وعيادة ليلاك.

الكلمات المفتاحية: تصنيف الصور، زيادة البيانات، صور التخطيط بالصدى لمستوى الجنين، EfficientNetB0، CNN.

# Table des matières

Remerciements.....	i
Dédicaces .....	ii
Dédicaces .....	iii
Résumé.....	iv
Abstract .....	iv
ملخص .....	iv
Table des matières .....	v
Liste des figures.....	viii
Liste des tableaux.....	xi
Listes des abréviations.....	xii
Introduction Générale .....	1
<b><u>CHAPITRE I</u></b>	
<b>I. Introduction</b> .....	3
<b>I.1 Le système reproducteur féminin</b> .....	3
I.1.1 Fonctionnement .....	4
<b>I.2 Développement du Fœtus</b> .....	4
I.2.1 Premier trimestre : de la fécondation à 13 semaines .....	4
I.2.2 Deuxième trimestre : de 14 à 27 semaines .....	5
I.2.3 Troisième trimestre : de 28 semaines à la naissance .....	7
<b>I.3 Echographie</b> .....	8
I.3.1 Histoire .....	8
I.3.2 L'utilisation de l'échographie.....	9
I.3.3 Echographie lors de la grossesse .....	10
I.3.3.1 La première échographie .....	11
I.3.3.2 la deuxième échographie .....	13
I.3.3.3 La troisième et dernière échographie.....	14
<b>I.4 Pathologies</b> .....	14
<b>I.5 Conclusion</b> .....	17
<b><u>CHAPITRE II</u></b>	
<b>II. Introduction</b> .....	18
<b>II.1 Apprentissage automatique</b> .....	18
II. 1.1 Techniques d'apprentissage automatique .....	20

II. 1.1.1 Apprentissage Supervisé .....	20
II. 1.1.2 Apprentissage Non Supervisé .....	20
II. 1.1.3 Apprentissage Par Renforcement (RL) .....	21
<b>II.2 Réseaux de Neurones</b> .....	21
II.2.1 Le neurone biologique .....	21
II.2.2 Le Neurone Artificiel .....	22
II.2.2.1 Les interconnexions d'un réseau de neurones.....	24
<b>II.3 Deep Learning</b> .....	24
II.3.1 Fonctionnement de l'Apprentissage Profond.....	25
II.3.2 Deep Learning versus Machine Learning .....	26
II.3.3 Types de réseaux de neurones profonds.....	27
II.3.3.1 Réseau de neurone récurrent / Recurrent Neural Networks (RNN).....	27
II.3.3.2 Les machines de Boltzmann restreintes / Restricted Boltzmann Machine (RBMs) ....	27
II.3.3.3 Réseaux antagonistes génératifs / Generative Adversarial Networks (GANs) .....	28
II.3.3.4 Les réseaux de neurones convolutionnels / Convolutional Neural Networks (CNNs) 28	
<b>II.4 Conclusion</b> .....	39
<b><u>CHAPITRE III</u></b>	
<b>III. Introduction</b> .....	40
<b>III. 1 Les outils, logiciels et les libraires utilisés</b> .....	40
III. 1.1 Python.....	40
III. 1.2 TensorFlow .....	40
III.1.3 Keras .....	41
III. 1.4 Jupyter Notebook and Google Colaboratory .....	42
<b>III. 2 Matériels utilisés</b> .....	42
<b>III.3 Data sets</b> .....	42
<b>III.4 Création de classes</b> .....	43
<b>III.5 Les mesures de performance</b> .....	43
III.5.1 Matrice de Confusion .....	43
III.5.2 Accuracy (Taux de classification) .....	44
III.5.3 Recall .....	44
III.5.4 Précision .....	44
III.5.5 F1-Score.....	44
<b>III.6 Forme de notre modèle</b> .....	45

III.6.1 Architecture du modèle 1 (EfficientNetB0).....	45
III.6.2 Architecture du modèle 2 (ResNet50) .....	45
III.6.3 Architecture du modèle 3 (Inception_V3).....	46
<b>III.7 Résultats et Discussion</b> .....	47
III.7.1 Epoque de 12 et la classe Categorical Crossentropy comme perte.....	47
III.7.2 Epoque de 14 et la classe Categorical Crossentropy comme perte.....	49
III.7.3 Epoque de 15 et la classe Categorical Crossentropy comme perte.....	51
Conclusion résultant : .....	53
<b>III.8 Augmentation des données</b> .....	54
<b>III.9 Conclusion</b> .....	57
<b>Conclusion Générale</b> .....	58
<b>Glossaires</b> .....	60
<b>Références</b> .....	61

# Liste des figures

## CHAPITRE I

Figure I. 1 Système reproducteur féminin.....	3
Figure I. 2 Embryon vers fœtus pendant la première trimestre.....	5
Figure I. 3 Développement du fœtus pendant le deuxième trimestre .....	6
Figure I. 4 Fœtus à la fin du troisième trimestre .....	8
Figure I. 5 a) transducteurs d’ultrasons et b) machine d’échographie .....	9
Figure I. 6 Crown-Rump Length.....	11
Figure I. 7 Biparietal Diameter (BPD), Head Circumference (HC), OccipitoFrontal Diameter .....	12
Figure I. 8 L'épiphyse cartilagineuse des condyles (C) et du grand trochanter (T) .....	12
Figure I. 9 Circonférence abdominale avec Veine Ombilicale (Umbilicale Vein), Rachis (Spine) et Estomac (Stomach).....	13
Figure I. 10 Croissance approximative, croissance symétrique et croissance asymétrique.	16
Figure I. 11 La Hauteur Utérine avec sommet de l’os pubien (pubic bone) et sommet d’utérus (top of utérus).....	16

## CHAPITRE II

Figure II. 1 De l’intelligence artificielle à l’apprentissage profond.....	18
Figure II. 2 les différentes approches de l’apprentissage automatique .....	21
Figure II. 3 Le neurone biologique .....	22
Figure II. 4 Schéma d’un neurone artificiel .....	23
Figure II. 5 Schéma de réseau monocouche (a) et réseau multicouche (b).....	24
Figure II. 6 Démonstration de la retro propagation.....	25
Figure II. 7 Processus de machine learning et deep learning.....	27
Figure II. 8 Couche de convolution avec un noyau 3×3 .....	30
Figure II. 9 Convolution d’une image avec P=1, S=1, N = 6 et F= 3 .....	31
Figure II. 10 Deux types de sous-échantillonnage avec un pas de 2.....	32
Figure II. 11 Graphe de la fonction ReLU .....	32
Figure II. 12 Exemple de l’application de softmax.....	33
Figure II. 13 Les couches de CNN.....	34
Figure II. 14 L’architecture de LeNet-5 .....	34

Figure II. 15 AlexNet Architecture .....	35
Figure II. 16 L'architecture de VGG.....	35
Figure II. 17 Module d'Inception avec réductions dimensionnelles.....	36
Figure II. 18 L'architecture de GoogleNet avec classificateurs auxiliaires .....	37
Figure II. 19 Architecture de ResNet-18 et Module de ResNet.....	37
Figure II. 20 Figure II. 20 Architecture d'EfficientNetB0.....	38
Figure II. 21 Transfer Learning.....	39
<b><u>CHAPITRE III</u></b>	
Figure III. 1 Python Logo.....	40
Figure III. 2 TensorFlow .....	41
Figure III. 3 Logo de Keras.....	41
Figure III. 4 Jupyter and Colab logo .....	42
Figure III. 5 Les cinq classes des images (Head : Tête, Abdomen : Abdomen, Thorax : Thorax, Femur : Fémur et Amniotic fluid : Liquide amniotique).....	43
Figure III. 6 Exemples des images de chaque classe avec 1 : Tête, 2 : Abdomen, 3 : Thorax, 4 : Fémur et 5 : Liquide amniotique.....	43
Figure III. 7 Configuration d'EfficientNetB0.....	45
Figure III. 8 Configuration d'Efficient après Transfer Learning .....	45
Figure III. 9 Configuration de ResNet .....	46
Figure III. 10 Configuration de ResNet après Transfer Learning.....	46
Figure III. 11 Configuration d'InceptionV3.....	47
Figure III. 12 Configuration d'InceptionV3 après Transfer Learning .....	47
Figure III. 13 Histogramme du taux de classification des trois modèles avec Optimiseur Adam à Epoque 12.....	47
Figure III. 14 Histogramme de F1-Score avec Adam .....	48
Figure III. 15 Histogramme de F1-Score avec Optimiseur Nadam .....	48
Figure III. 16 Histogramme de F1-Score avec Optimiseur SGD.....	49
Figure III. 17 Histogramme du taux de classification des trois modèles avec Optimiseur Adam à Epoque 14.....	49
Figure III. 18 Histogramme de F1-Score avec Adam .....	50

Figure III. 19 Histogramme de F1-Score avec Optimiseur Nadam .....	50
Figure III. 20 Histogramme de F1-Score avec Optimiseur SGD.....	51
Figure III. 21 Histogramme du taux de classification avec Optimiseur Adam à Epoque 15 .....	51
Figure III. 22 Histogramme de F1-Score à Epoque 15 avec Adam .....	52
Figure III. 23 Histogramme de F1-Score à Epoque 15 avec Nadam .....	52
Figure III. 24 Histogramme de F1-Score avec Optimiseur SGD.....	53
Figure III. 25 Graphe du taux de classification et la perte de l'apprentissage et la validation d'EfficientNetB0 avec Adam.....	54
Figure III. 26 La matrice de confusion du modèle.....	54
Figure III. 27 Exemples d'images augmentées.....	55
Figure III. 28 Histogramme de F1-Score d'EfficientNetB0 avec Adam après l'augmentation des images .....	55
Figure III. 29 Graphe du taux de classification et la perte de l'apprentissage et la validation d'EfficientNetB0 après l'augmentation des images.....	56
Figure III. 30 Matrice de confusion d'EfficientNetB0 après l'augmentation des images. ..	56

## Liste des tableaux

### CHAPITRE II

Tableau II.1 Tableau des fonctions d'activation .....32

### CHAPITRE III

Tableau III.1 Matrice de Confusion .....44

## Listes des abréviations

Adam : Adaptive moment estimation

AI : Artificial Intelligence

CNN : Convolutional Neural Network

dB: Decibel

DL: Deep Learning

DS : Déviation Standard

EPH : Etablissement Public Hospitalier

FF: Feed Forward

GPU : Processeur Graphique

ILSVRC : ImageNet Large Scale Visual Recognition Challenge

ML: Machine Learning

mmHg: millimètres de mercure

Nadam: Nesterov-accelerated Adaptive Moment Estimation

PAG /FSGA : Petit poids pour l'âge gestationnel/ Small for Gestational Age

RCIU : Retard de Croissance Intra-Utérine

SA : Semaine d'aménorrhée

SGD : Stochastic gradient descent

SVM : Support Vector Machine (Vecteur de support machine)

UMBB : Université Mohammed Bougara Boumerdès

# Introduction Générale

## ✓ Contexte

Dans la médecine moderne, l'imagerie médicale a subi d'immenses progrès grâce auxquels elle peut capturer plusieurs images biomédicales de patients. Ces images peuvent être utilisées et entraînées dans un système intelligent afin d'aider à la détermination des différentes pathologies qui peuvent être identifiées à partir de l'analyse de ces images. La classification y joue un rôle clé en facilitant le regroupement de ces images en différentes catégories et optimise ainsi le système de diagnostic assisté par ordinateur. Le concept de classification dans l'apprentissage automatique traite du problème d'identification à quel ensemble de catégories appartient une population donnée. Une fois cet objectif atteint, la classification est effectuée sur la base de l'apprentissage d'un ensemble de données donné contenant les résultats observés.

L'application des méthodes d'apprentissage automatique, en particulier le Deep Learning (DL) au domaine de la classification d'images biomédicales est devenue de plus en plus populaire récemment. Le processus de classification des images biomédicales passe généralement par deux canaux principaux :

1. Phase d'apprentissage : les ensembles de données sont de préférence divisés en deux ensembles de données à grande échelle et à moyenne échelle, suivis d'une extraction de caractéristiques qui est exécutée par des algorithmes DL dans ce but.
2. Phase de test : la moindre partie de l'ensemble de données peut être utilisée pour tester le modèle CNN spécialisé pour la classification des images. Il passe par la sélection des caractéristiques, après l'algorithme DL précédemment utilisé est appliqué à l'apprentissage d'un modèle CNN de pointe choisi ou d'un modèle construit à partir de zéro, c'est ce qu'on appelle le modèle de classificateur. Cette étape est suivie d'une prédiction par le modèle déterminant son taux de classification.

## ✓ Problématique

Les grossesses sont à risques de RCIU entre autres pathologies. L'identification et le diagnostic précoces de cette pathologie est un défi dans le domaine médical en raison

de la médiocrité des services médicaux dans les pays moins développés, de la classification et de la segmentation manuelles des images fœtales ou de la mauvaise interprétation des pathologies qui peuvent sembler similaires au RCIU. La question se pose alors : comment réduire le risque de bébés prématurés, de bébés avec RCIU, de complications et de décès de femmes enceintes et d'éventuels faux diagnostics à l'aide d'un système intelligent ?

### ✓ But du travail

L'objectif principal de notre travail est de faire la classification automatisée des images biométriques fœtales qui sont pris pour l'examen de la pathologie RCIU en utilisant les techniques avancées de l'apprentissage profond.

### ✓ Méthodologie

Nous avons utilisé le langage Python sur les plateformes Google Colab et Jupyter Notebook d'implémenter le concept de l'apprentissage par transfert sur les modèles de CNN en changeant certains paramètres et couches des modèles qui nous a aidé de classifier les images selon leurs classes : Tête, Abdomen, Thorax, Fémur et Liquide Amniotique. Nous avons aussi utilisé le concept d'augmentation des données qui change la géométrie à travers des méthodes tels que ; retournement aléatoire, décalage horizontal et verticale, etc. ce concept permet la génération des nouvelles images qui augmente le nombre total des images.

### ✓ Organisation du mémoire

L'organisation du travail est faite en trois chapitres :

- Le premier chapitre est consacré aux parties du système reproducteur féminin, les étapes détaillées de la grossesse, développement du fœtus a un bébé et les échographies. Aussi, les pathologies possibles à la grossesse et du bébé.
- Dans le deuxième chapitre, nous avons les différentes techniques d'apprentissage automatique et en profondeur, la base de ces apprentissages : Réseaux de neurones et les CNN avec certaines architectures.
- Les logiciels, outils, bibliothèques et la classification de ces images ont été examiné dans le troisième chapitre.

# CHAPITRE I

---

LE DEVELOPPEMENT ET LES  
PATHOLOGIES D'UN FŒTUS

## I. Introduction

Nous présentons dans ce premier chapitre, le système reproducteur féminin et son fonctionnement, puis une description sur le développement d'un embryon à un bébé et les consultations à prendre chez un médecin à l'hôpital. Nous élaborons aussi, certaines pathologies pendant la grossesse et principalement, le Retard de Croissance Intra-Utérine, ses généralités et comment le diagnostiquer.

### I.1 Le système reproducteur féminin

C'est l'un des onze principaux systèmes d'organes du corps humain. Cela est composé de **la vulve** qui est une région située dans le périnée, **du vagin** qui est un canal qui relie le col de l'utérus (la partie inférieure de l'utérus) à l'extérieur du corps. Il est également connu comme le canal de naissance, **de l'utérus** qui est une poche prévue pour accueillir un embryon et favoriser son développement, **des trompes de Fallope** qui sont des tubes étroits qui sont attachés à la partie supérieure de l'utérus et servent de voies pour que les ovules se déplacent des ovaires à l'utérus et **des ovaires** qui sont de petites glandes de forme ovale situées de chaque côté de l'utérus [1], [2].

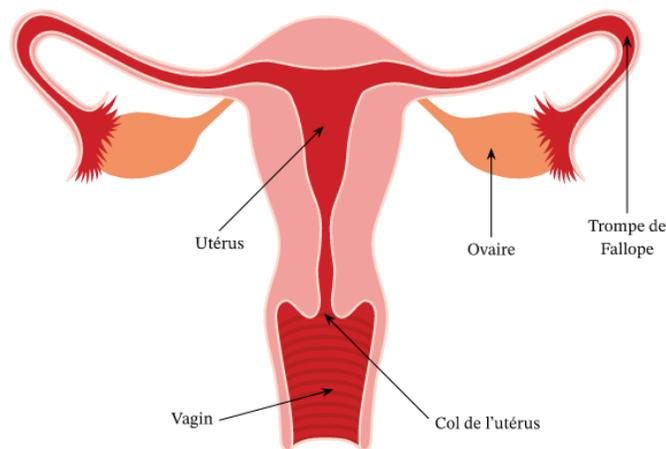


Figure I. 1 Système reproducteur féminin [1]

### I.1.1 Fonctionnement

Le système reproducteur féminin assure plusieurs fonctions. Les ovaires produisent les ovules, appelés ovocytes. Les ovocytes sont ensuite transportés vers la trompe de Fallope où la fécondation par un spermatozoïde peut avoir lieu. Si l'implantation n'a pas lieu, la muqueuse utérine est éliminée sous forme de flux menstruel.

Contrairement, lorsque la fécondation a eu lieu, l'œuf se déplace ensuite vers l'utérus et s'implante dans la muqueuse utérine qui s'est épaissie jusqu'à 35 centimètres en réponse aux hormones normales du cycle de reproduction et continue à se développer [2], [3]. Ce processus est appelé « la grossesse » et le début de la grossesse est en fait le premier jour de vos dernières menstruations. C'est ce qu'on appelle **l'âge gestationnel**. [3]

## I.2 Développement du Fœtus

Dans les 24 heures suivant la fécondation, l'œuf qui deviendra un bébé se divise rapidement en deux, puis quatre jusqu'à vingt-quatre cellules. À la huitième semaine de grossesse, l'embryon se transforme en fœtus et son développement est essentiellement centré sur la croissance, en taille et en poids, du futur bébé. Il y a environ 40 semaines pour une grossesse typique. Ces semaines sont divisées en trois trimestres [2], [3].

### I.2.1 Premier trimestre : de la fécondation à 13 semaines

Au fur et à mesure que l'œuf fécondé grandit, un sac étanche se forme autour de lui, se remplissant progressivement de liquide. C'est ce qu'on appelle le sac amniotique, et il aide à amortir la croissance de l'embryon.

Pendant ce temps, le placenta se développe également. **Le placenta** étant un organe rond et plat permet des échanges foeto-maternels et se connecte au fœtus via le cordon ombilical. Cet organe est généralement attaché au sommet, au côté, à l'avant ou à l'arrière de l'utérus.

Au cours de ces premières semaines, un visage primitif prendra forme avec de larges cernes en guise d'yeux. La bouche, la mâchoire inférieure et la gorge se développent. Les cellules sanguines prennent forme et la circulation commence. Le minuscule tube "cœur" battra 65 fois par minute d'ici la fin de la quatrième semaine. À la fin du premier mois, le fœtus mesure environ 5 mm de long. [3]

Le cœur commence à battre à la 5<sup>e</sup> semaine ; le cerveau, les organes, les membres et les premiers muscles se développent au cours des semaines suivantes. Les oreilles et les yeux sont déjà bien reconnaissables sur la tête qui est beaucoup plus grosse que le reste de son corps à la 7<sup>e</sup> semaine [4]. A partir de la 9<sup>e</sup> semaine, le bébé commence à bouger et ses sens se développent. Vers la fin de ce trimestre, le grandissement du fœtus continue et les os de son squelette commencent à se former. A la fin du premier trimestre de la grossesse, il pèse jusqu'à 0,05 kg et mesure jusqu'à 8 cm. De toutes les phases de grossesse, le premier trimestre est la plus critique car le risque de fausse couche est élevé.

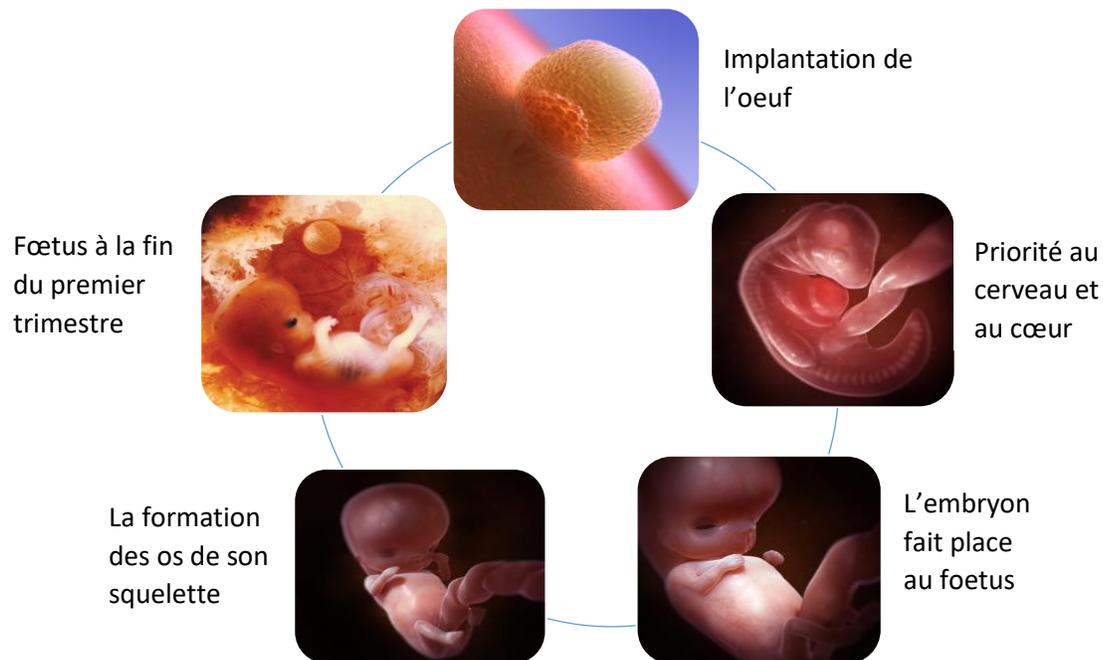


Figure I. 2 Embryon vers fœtus pendant la première trimestre [4], [5]

### I.2.2 Deuxième trimestre : de 14 à 27 semaines

Le rythme cardiaque fœtal peut maintenant être audible grâce à un instrument appelé **doppler**. Les dents et les os deviennent plus denses. Le système nerveux commence à fonctionner. Les organes reproducteurs et les organes génitaux sont maintenant complètement développés et votre médecin peut voir à l'échographie si le fœtus sera désigné mâle ou femelle à la naissance.

À la fin du quatrième mois, le fœtus mesure environ 11,5cm de long et pèse environ 0,11 kg. Les premiers mouvements sont appelé accélération et devient plus prononcés et assez forts pour que vous les perceviez. [3]

Les épaules, le dos et les tempes sont recouverts d'un poil fin et doux appelé **lanugo**. Ces poils protègent le fœtus et tombent généralement à la fin de la première semaine de vie du bébé. Les cheveux commencent à pousser sur la tête qui semble toujours disproportionnée par rapport au reste du corps, mais son tronc, ses bras et ses jambes commencent à s'allonger [4]. La peau est recouverte d'un revêtement blanchâtre appelé vernix caseosa qui protège la peau du fœtus de la longue exposition au liquide amniotique. Ce revêtement est versé juste avant la naissance. [3]

À la fin de la 20e semaine, le fœtus mesure environ 16cm de long et pèse de 0,23-0,45 kg. À ce stade, les paupières commencent à s'écarter et les yeux s'ouvrent.

Le fœtus continue de mûrir et de développer des réserves de graisse corporelle. À ce stade, l'ouïe est pleinement développée. Le fœtus change fréquemment de position et réagit aux stimuli, y compris le son, la douleur et la lumière. Le liquide amniotique commence à diminuer. Entre 23 et 27 semaines, le bébé prend du poids et sa tête devient mieux proportionnée par rapport à son corps.

Du sixième au septième mois, la taille et le poids du fœtus augmentent d'environ 22,5cm et environ 0,9 kg à environ 25cm et 1,81 kg respectivement. [3], [4].

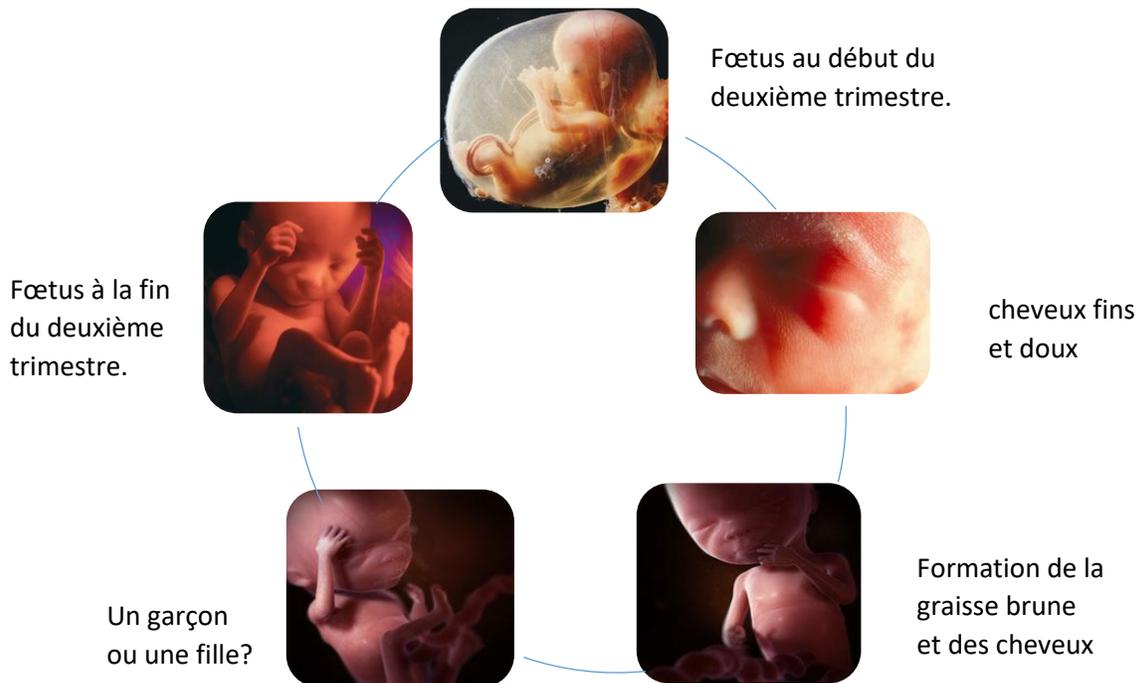


Figure I. 3 Développement du fœtus pendant le deuxième trimestre [4], [5]

### I.2.3 Troisième trimestre : de 28 semaines à la naissance

Aux semaines 28 à 32, le cerveau se développe rapidement à ce moment et le fœtus peut voir et entendre. À travers du liquide amniotique, il enregistre un éventail de saveurs et des odeurs susceptibles. La plupart des systèmes internes sont bien développés, mais les poumons et les reins peuvent encore être immatures. Les mouvements respiratoires sont de plus en plus réguliers et son cœur bat au rythme de 135 à 140 battements par minute. Le fœtus s'agit et fait de grands mouvements des bras ou des jambes et mesure environ 28cm de long et pèse jusqu'à 1,7kgs. [3], [5].

Aux semaines 33 à 36, au cours de cette étape, le fœtus a beaucoup moins de place pour bouger mais ses mouvements peuvent être toujours détectés. Les poumons sont sur le point d'être complètement développés à ce stade sachant que ses développements sont les plus longs et termineront leur développement à la naissance. Deux importantes structures ont atteint leur maturité :

- Le cerveau
- Le système immunitaire.

Le fœtus mesure environ 34cm de long et pèse de 2,5 kg à 3 kg.

Aux semaines 37 à 40, le fœtus est maintenant considéré comme étant à terme. La couche de vernix est maintenant détachée et flotte dans le liquide amniotique qui prend une couleur laiteuse. Ses membres sont repliés et près du corps, son menton repose sur ses genoux et sa croissance est maintenant au ralenti, mais il continue à grossir et il basculera tête en bas, en vue de l'accouchement. Le fœtus mesure maintenant autour de 50 cm des pieds à la tête et son poids ne devrait pas vraiment changer d'ici sa naissance et tournera autour de 3,5 -4 kg. Les garçons ont tendance à être un peu plus gros que les filles à la naissance. [5]

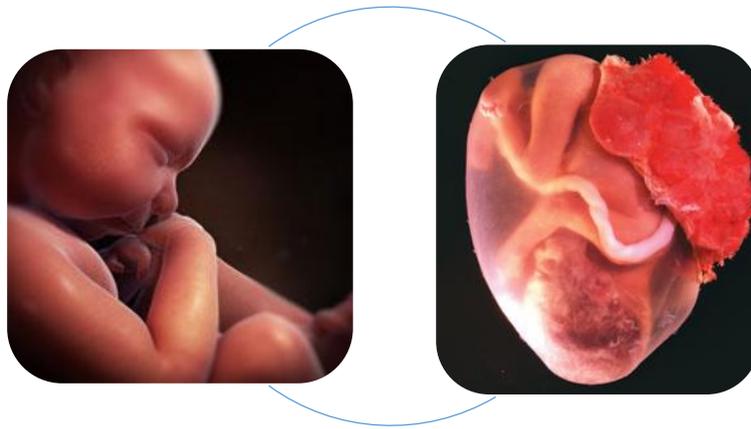


Figure I. 4 Fœtus à la fin du troisième trimestre [4], [5].

### I.3 Echographie

L'échographie est une étape indispensable lors d'une grossesse considérée comme une enquête sûre, invasive (Parfois, on utilise une sonde qui se met dans le vagin. Cela permet d'avoir une meilleure image et capter plus d'information également connu sous le nom de scans transvaginaux) et non invasive, précise et efficace sur le fœtus. C'est une technique de *diagnostic* par imagerie très utile qui utilise les ultrasons émis par une sonde pour voir le bébé à l'intérieur du ventre de la mère [6]. Son principe est basé sur l'**effet doppler** « lorsque les impulsions d'ultrasons voyagent d'un transducteur à une cible mobile où ils sont réfléchis vers le transducteur » [7] où les informations obtenues à partir de différentes réflexions sont recomposées en une image sur l'écran du moniteur. [8]

#### I.3.1 Histoire

L'évolution de l'échographie a commencé du mode A (une série de pointes vertes sur un écran), décrit pour la première fois par *Ian Donald* pour la gynécologie à la fin des années 1950, au mode B (points blancs) dans les années 1970, en temps réel et en niveaux de gris au début des années 1980, à des Doppler couleur dans les années 1990 et échographie tridimensionnelle ou quadridimensionnelle dans les années 2000. Les premières images échographiques d'une tête fœtale ont été réalisées et publiées en juin 1958 avec l'Article du

Lancet du professeur Ian Donald sur le diagnostic du kyste ovarien avec une technologie nouvellement appliquée à la médecine : Ultrason [8].

### I.3.2 L'utilisation de l'échographie

Les équipements utilisés en échographie comprennent une machine d'échographie, un transducteur approprié et, pour les examens de contraste, un produit de contraste et ces équipements sont utilisés en temps réel.

Un transducteur « Appelé aussi **une Sonde** est formée d'éléments piézo-électriques qui traduisent un signal électrique en variations de pression donc en signal acoustique » est mis en contact avec un gel pour éliminer l'air sur l'abdomen maternel et ce transducteur est déplacé pour regarder le contenu de l'utérus [8].

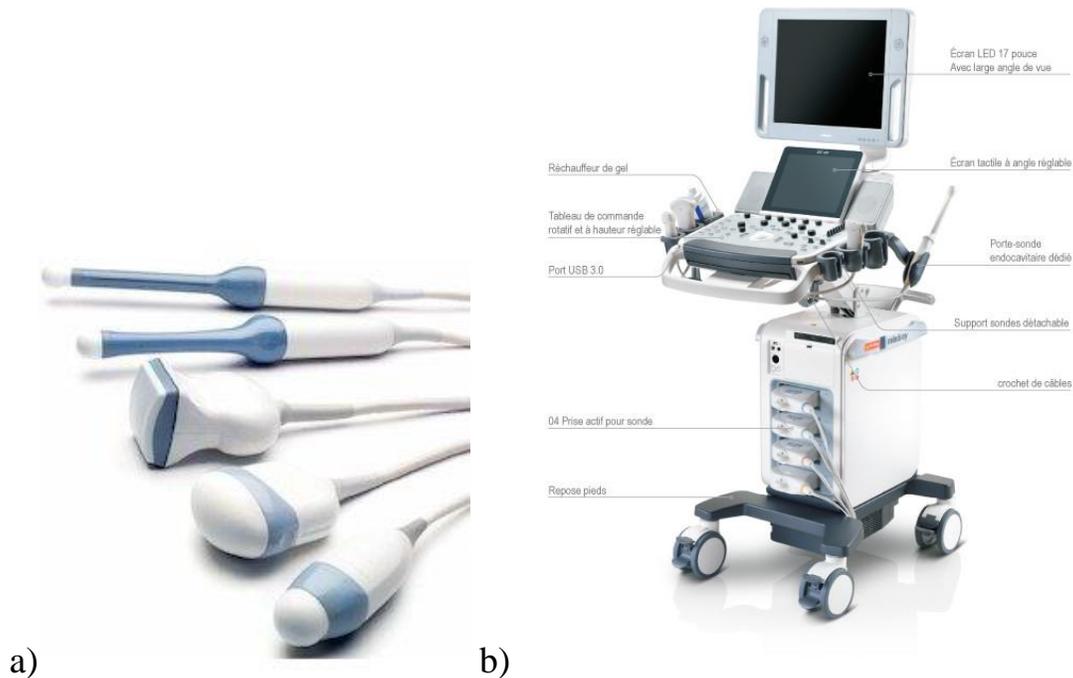


Figure I. 5 a) transducteurs d'ultrasons et b) machine d'échographie [9], [10]

Les images produites en échographie sont des résultats de l'interaction entre l'onde ultrasonore et les tissus étudiés. Lorsque l'onde est émise, elle interagit avec les tissus par divers processus ce qui réduit son intensité exprimée en décibels (dB) « atténuation ». Les principaux processus d'interaction comprennent la réflexion, la réfraction, absorption et diffusion qui sont affectés par la fréquence du faisceau d'ultrasons, et les propriétés physiques (densité, élasticité et viscosité) du milieu à travers lequel le faisceau passe.

Une interface fortement réfléchissante telle que celle entre le gaz et les tissus mous agit comme une barrière à la propagation des ultrasons en renvoyant la quasi-totalité de l'énergie rayonnée. De même, un milieu fortement absorbant tel que l'os enlève l'énergie du faisceau en convertissant l'énergie absorbée en une autre forme d'énergie, généralement de la chaleur qui jette ensuite une acoustique ombre derrière elle, parce qu'il reste trop peu de l'onde pour une interrogation plus approfondie des structures situées au-delà. En revanche, les cavités liquides ne réfléchissent pas et se présentent donc comme caractéristiques sans écho zones (fenêtres acoustiques à travers lesquelles les ultrasons parcourent de longues distances). [11]

L'échographie utilise le principe d'impulsion-écho avec deux méthodes d'émission :

- **Ultrasons à ondes continues** (Continuous Waves - CW) où l'émission est continue, et un détecteur séparé est nécessaire pour recevoir les échos de retour.
- **Ondes pulsées** (Pulsed Waves - PW) sont les impulsions courtes et intermittentes, avec des intervalles entre elles.

La représentation la plus simple du signal échographique est celle de son amplitude en fonction du temps de propagation de l'onde ultrasonore sous forme d'images en utilisant une échelle de gris et pour présenter et visualiser ce signal obtenue, ces trois opérations suivantes sont nécessaires à faire :

- compenser l'atténuation des ultrasons en fonction de la profondeur traversée,
- faire ressortir les faibles échos par rapport aux forts,
- adapter la dynamique du signal échographique à la dynamique maximum de la lumière perçue par l'œil, dans les conditions habituelles de visualisation [12].

### I.3.3 Echographie lors de la grossesse

Pendant tous les trimestres de la grossesse, un examen d'échographie est réalisé pour obtenir des informations importantes sur le bébé et la mère afin d'assurer un bon accouchement. Cet examen commence autour de 11<sup>ème</sup> semaine de la grossesse mais dans certains cas, il faut des autres échographies. En général, c'est divisé en trois :

### I.3.3.1 La première échographie

C'est aussi appelée échographie de datation. Elle doit avoir lieu entre 11 et 13 **semaines d'aménorrhée** (SA) et cela correspond aux 9, 10 et 11<sup>ème</sup> **semaines de grossesse** (soit environ 3 mois de grossesse), durant environ 30 minutes [13]. Cet examen permet [14] :

- ❖ Parfois de connaître le sexe du bébé.
- ❖ De vérifier combien il y a de bébés
- ❖ D'observer la majorité des organes (cœur, foie, reins, estomac, vessie, cerveau, etc.) et les membres du bébé pour la vitalité fœtale.
- ❖ De déterminer l'emplacement du placenta
- ❖ Évaluer les risques d'anomalies et d'autres pathologies : Par exemple, mesurer la clarté nucale, c'est-à-dire l'espace entre la peau du cou et la colonne vertébrale du fœtus pour le calcul de trisomie 21 [13].
- ❖ D'observer le développement du bébé ;

Les mesures suivantes sont généralement effectuées

- a) La longueur couronne-croupe (Crown-Rump Length - CRL) c'est-à-dire la distance entre le sommet de la tête et le bas des fesses pendant 7-13 semaines.

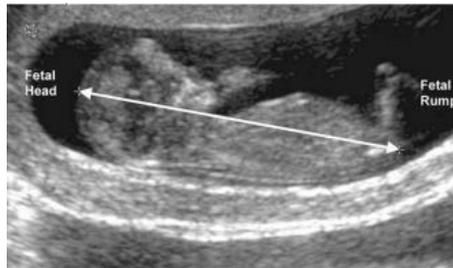


Figure I. 6 Crown-Rump Length [15]

- b) Le diamètre bipariétal (Biparietal Diameter - BPD) Se mesure après 13 semaines entre les 2 côtés de la tête. Il passe d'environ 2,4 cm à 13 semaines à environ 9,5 cm à terme. NB : différents bébés de même poids peuvent avoir des tailles de tête différentes. La BPD doit être mesurée sur un plan axial qui traverse le thalami et le cavum septum pellucidum. Le transducteur doit être perpendiculaire à l'axe central de la tête, donc les hémisphères et la calotte crânienne doivent apparaître symétriques. Les étriers doivent être placés au :
  - bord extérieur du mur près du calvaire

- bord intérieur de la paroi calvariale éloignée

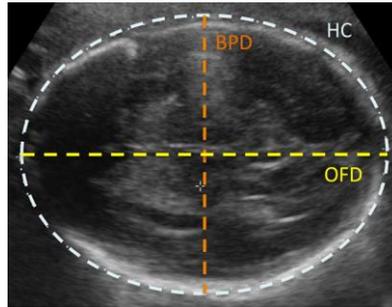


Figure I. 7 Biparietal Diameter (BPD), Head Circumference (HC), Occipitofrontal Diameter [15]

c) La longueur du fémur (Femur Length - FL)

Il reflète la croissance longitudinale du fœtus. Il passe d'environ 1,5 cm à 14 semaines à environ 7,8 cm à terme. Le fémur est abordé de manière à ce que le fût diaphysaire apparaisse horizontalement à l'écran. Les marqueurs sont positionnés aux deux extrémités du fût diaphysaire.



Figure I. 8 L'épiphyse cartilagineuse des condyles (C) et du grand trochanter (T) [15].

c) La circonférence abdominale (Abdominal Circumference - AC)

Diamètre abdominal transverse (DAT) : Il s'agit d'une coupe transversale de l'abdomen fœtal, passant par les trois points de repère que sont :

- Estomac fœtal
- Veine ombilicale
- Rachis

La circonférence abdominale est mesurée dans le plan axial où l'estomac est vu sur le côté gauche, la veine ombilicale et la veine porte gauche se

rejoignent dans le foie sur la droite et les trois os de la colonne vertébrale transversale sont vus dans le même plan. L'AC se fait en plaçant des étrières sur la surface externe de la peau de l'abdomen circulaire.

Circonférence abdominale = (AP + Transverse) x 1,57 où AP est Abdominal Perimeter (Périmètre Abdominale).



Figure I. 9 Circonférence abdominale avec Veine Ombilicale (Umbilical Vein), Rachis (Spine) et Estomac (Stomach) [15].

#### d) Poids du fœtus

Utilisation d'équations polynomiales contenant BPD, FL, AC et HC.

#### ❖ De déterminer plus précisément l'âge de la grossesse ;

Les mesures du corps fœtal reflètent l'âge gestationnel du fœtus. Chez les patientes dont les dernières menstruations sont incertaines, les mesures doivent être effectuées le plus tôt possible pendant la grossesse, pour arriver à une datation correcte pour une patiente [16].

#### I.3.3.2 la deuxième échographie

Cette échographie, appelé l'échographie morphologique, est pratique entre la 18e et la 22e semaine de grossesse qui correspond aux 22ème et 24ème semaine d'aménorrhée. Elle permet à poursuivre ce dépistage prénatal des maladies [17] et vérifier :

- La position et l'âge du bébé
- La croissance et le développement en fonction de l'âge du bébé ;
- La longueur du col de l'utérus. [6]

### I.3.3.3 La troisième et dernière échographie

Elle se fait entre la 30<sup>ème</sup> et la 32<sup>ème</sup> semaine (32<sup>ème</sup> et 34<sup>ème</sup> semaine d'aménorrhée) pour vérifier la quantité de liquide amniotique, la présentation du fœtus, identifier un éventuel retard de croissance intra-utérin (RCIU) etc. [4], [5].

## I.4 Pathologies

Selon le dictionnaire, une pathologie est définie comme tout écart par rapport à une structure ou une fonction saine ou normale ; anomalie mais plus précisément **Une grossesse pathologique** est définie par des complications qui surviennent en cours de grossesse et/ou de l'accouchement. Elles impliquent la maman et/ou le bébé et nécessitent une prise en charge spécifique et un suivi de grossesse accru [18]. Il existe plusieurs mais les plus fréquentes sont les suivants :

- a) **Hypertension artérielle (HTA) ou pré éclampsie** : La pré éclampsie est l'association d'une HTA (pression artérielle systolique  $> 140$  mmHg et pression artérielle diastolique  $> 90$  mmHg) à une protéinurie « la présence de protéines dans les urines » (supérieure à 0,3 g/24 h) [19].
- b) **Diabète gestationnel** : Le diabète gestationnel est un trouble de la tolérance glucidique conduisant à une hyperglycémie de sévérité variable, débutant ou diagnostiquée pour la première fois pendant la grossesse parce que la grossesse modifie le métabolisme du sucre [19]. Si le diabète n'est pas pris en charge, des complications pour le bébé peuvent survenir ; par exemple le bébé peut devenir trop gros qui peut causer des problèmes lors de l'accouchement ou peut présenter des hypoglycémies juste après la naissance [20].
- c) **Menace d'accouchement prématuré** : La menace d'accouchement prématuré est un cas qui peut conduire à la naissance d'un enfant prématuré (né avant 37 SA) [19]. Elle se caractérise par des modifications du col de l'utérus et des contractions utérines régulières et douloureuses survenant entre 22 et 36 semaines d'aménorrhée [21].
- d) **Placenta Prævia** : Le placenta prævia se produit lorsque le placenta se fixe à l'intérieur de l'utérus mais dans une position anormale près ou au-dessus de l'ouverture cervicale [22].

- e) **Grossesses extra-utérines** : est la nidation ectopique de l'œuf en-dehors de la cavité utérine. Les plus fréquentes sont des grossesses tubaires [23].
- f) **Rupture prématurée des membranes** : La rupture prématurée des membranes est la libération du liquide amniotique entourant le fœtus à tout moment avant le début du travail. Il peut mener à un risque important d'infection de la femme et du fœtus, décollement précoce du placenta de l'utérus, compression du cordon ombilical et accouchement par césarienne [24].
- g) **Retard de croissance intra-utérin (RCIU)** : Le RCIU, *en anglais Intra-Uterine Growth Retardation*, est défini par l'incapacité du fœtus à atteindre son potentiel de croissance c'est-à-dire il a une taille insuffisante pour l'âge gestationnel et un poids insuffisant (< au 10ème percentile) selon des courbes de référence pour l'âge gestationnel qui peut être causé par la diminution des échanges fœto-maternels par diminution du débit utéroplacentaire, anomalies fœtales, pathologie maternelle chronique etc. Les courbes de référence sont exprimées en percentile ou en Déviation Standard (DS) [25].

Il existe deux types de RCIU :

- Les RCIU symétriques (précoces), sont les cas où le corps entier d'un fœtus est proportionnellement petit, soit un rapport HC à AC de 1 : 1 à cause de l'utilisation de substances par la mère, anémie, etc.
- Les RCIU asymétriques (tardives), sont les cas où il y a une diminution de l'apport d'oxygène ou de nutriments au fœtus en raison d'une insuffisance placentaire où le sang est détourné vers les organes vitaux, tels que le cerveau et le cœur et, par conséquent, HC est normal et AC est diminué [26].

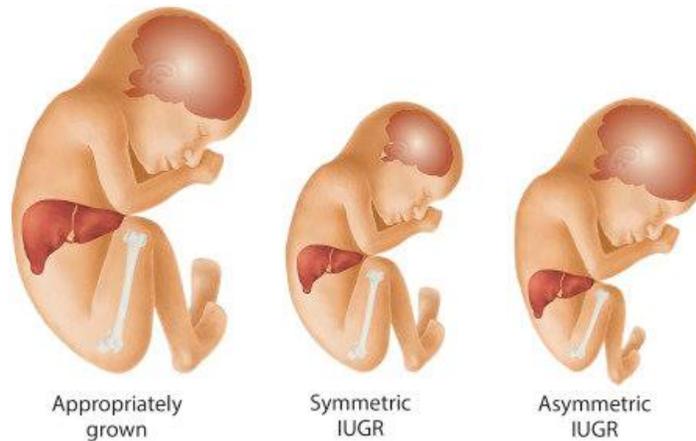


Figure I. 10 Croissance approximative, croissance symétrique et croissance asymétrique [27].

Aussi, il existe des niveaux de gravité variés :

- 5e ou 3e percentile = RCIU sévère,
- 10e percentile = suspect de RCIU ou RCIU peu sévère.

#### Comment un RCIU peut être diagnostiquer ?

Avant de faire la diagnostique du RCIU, son hypothèse doit être distinguée du Petit poids pour l'âge gestationnel (PAG)/Small for Gestational Age (SGA) qui permet d'identifier un groupe d'enfants à plus haut risque de problèmes de croissance **et** Faible poids de naissance/Low Birth Weight : inclut les enfants de faible poids de naissance (<2500 g), prématurés avec et sans retard de croissance intra-utérin, ainsi que les enfants à terme avec des RCIU [28].

Les RCIU peuvent être identifier par :

- La mesure de la Hauteur Utérine (HU) du ventre de la mère du sommet de l'os pubien au sommet de l'utérus. Cela permet d'évaluer la croissance de l'utérus [29].

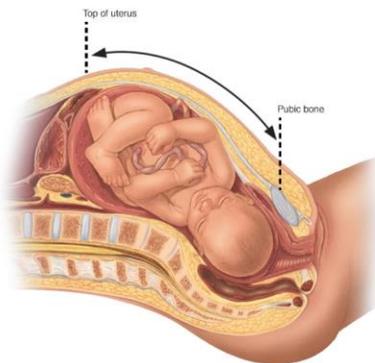


Figure I. 11 La Hauteur Utérine avec sommet de l'os pubien (pubic bone) et sommet d'utérus (top of uterus) [30]

- Biométrie échographique prénatale fait appel à plusieurs paramètres biométriques tels que BPD, HC, AC et FL pour estimer la taille et le poids du bébé. Elle peut également être utilisée pour identifier les problèmes avec le placenta ou une diminution du volume de liquide amniotique [29].

## **I.5 Conclusion**

Dans cette section, nous avons présenté le déroulement de la grossesse et la technique de diagnostic la plus utilisée (échographie) afin de prédire et identifier les pathologies qui peuvent affecter la femme et son bébé à partir des images échographiques du plan fœtal.

# CHAPITRE II

---

## LES METHODES DE CLASSIFICATION DES IMAGES

## II. Introduction

La création de l'intelligence artificielle (IA), « processus de transmission de données, d'informations et d'intelligence humaine aux machines », a permis dans le domaine médical, la numérisation et le traitement automatique des images, la simple utilisation des données saisies en langage naturel etc. la conception a été possible grâce au traitement itératif « Machine Learning (ML) » qui est une forme de l'IA et à l'apprentissage algorithmique « Deep Learning (DL) » qui est le sous-domaine du ML.

Nous allons, dans ce chapitre, décrire les méthodes de classifications, les réseaux de neurones convolutionnels et leurs différentes architectures.

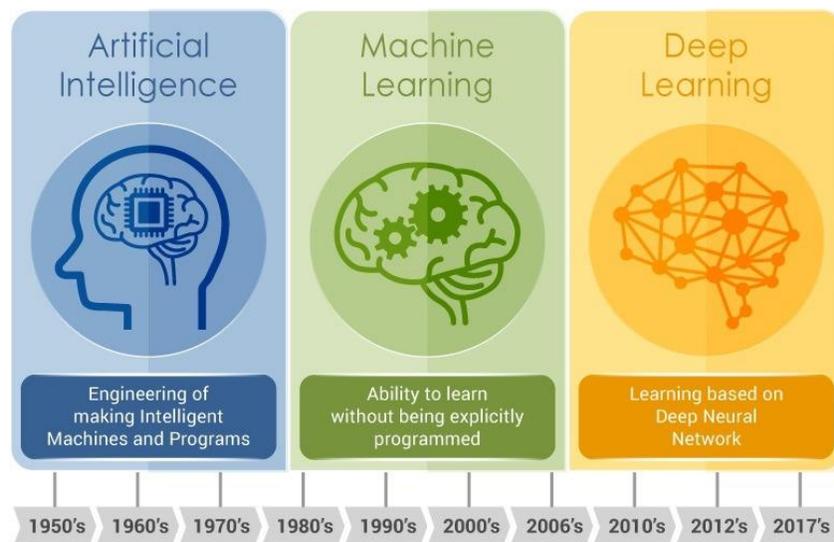


Figure II. 1 De l'intelligence artificielle à l'apprentissage profond [31]

### II.1 Apprentissage automatique

L'apprentissage automatique, en anglais Machine Learning (ML), est une forme d'intelligence artificielle (IA) qui confère aux systèmes la capacité d'apprendre et qui utilise des algorithmes informatiques et des analyses pour créer des modèles prédictifs à partir des données sans être explicitement programmés [32]. Le ML était souvent appelé IA jusqu'à la fin des années 1970, où il s'est diversifié pour évoluer par lui-même. Il est considéré comme un outil important pour l'objectif de tirer parti des technologies autour de l'intelligence artificielle et joue un rôle important dans nos activités quotidiennes telles que les services de

médias sociaux, filtrage des courriers indésirables et des logiciels malveillants, affinage des résultats des moteurs de recherche, cloud computing et commerce électronique, etc.

*Quand exactement dans le temps l'apprentissage automatique a-t-il commencé et où va-t-il ?*

1943, le logicien Walter Pitts et le neuroscientifique Warren McCulloch l'ont conceptualisé en publiant un article mathématique cartographiant le processus de prise de décision dans la cognition humaine et les réseaux neuronaux.

1950- Alan Turing a introduit le test de Turing.

1952- Arthur Samuel d'IBM a écrit le premier programme informatique qui jouait à un jeu de dames.

1957- le psychologue américain Frank Rosenblatt conçoit le perceptron, le premier réseau de neurones

Années 1960 et 1980 - introduction et réintroduction des concepts de rétro propagation respectueusement

De 1981 à 1995 - différents algorithmes comme l'algorithme d'apprentissage Q et les algorithmes de forêts aléatoires ont été introduits.

Le début des années 2000 a popularisé le clustering de vecteurs de support, l'apprentissage non supervisé et les méthodes du noyau pour l'apprentissage automatique, les réseaux de neurones convolutionnels en 2009, AlexNet en 2012, et DeepFace par Facebook et les réseaux antagonistes génératifs (GAN) par Ian Goodfellow en 2014.

En 2020 et au-delà, Facebook AI Research a introduit ReBeL et Deepmind ont introduit les reformulations non convexes efficaces. Google a également publié Switch Transformers pour former des modèles de langage. ML continue d'évoluer jusqu'à ce jour [33].

Il existe de nombreux secteurs dans lesquels l'apprentissage automatique peut être utilisé, mais dans cette étude, nous nous concentrerons sur la classification et la prédiction d'images.

Pour une machine, une image est un tableau de nombres indiquant la luminosité (ou la couleur) de chaque pixel [32]. Pour classifier une image, l'apprentissage automatique utilise les deux piliers fondamentaux des **réseaux de neurones** :

- Apprentissage : Les données, qui sont les exemples à partir duquel l'algorithme va apprendre, sont introduits dans l'entrée.
- Inférence : Les données inconnues sont introduites dans l'entrée et le système suggère une sortie.

## II. 1.1 Techniques d'apprentissage automatique

Le ML permet de créer des modèles qui sont entraînés pour reconnaître certains types de motifs et ces méthodes permettent de rendre ces modèles prédictifs plus précis.

### II. 1.1.1 Apprentissage Supervisé

C'est une approche de ML où la machine peut apprendre à faire une certaine tâche en étudiant des exemples de cette tâche. Elle est basée sur le concept d'un modèle qui relie des entrées données aux sorties souhaitées en déduisant une fonction à partir de données d'apprentissage étiquetées consistant d'un ensemble d'exemples d'apprentissage [34].

Les algorithmes les plus utilisés sont ; Machines à vecteurs de support (Support-vector machines), Régression linéaire (linear regression), Algorithme du K plus proche voisin (K-nearest neighbor algorithm), Réseaux de neurones (Perceptron multicouche).

### II. 1.1.2 Apprentissage Non Supervisé

Cette approche consiste à entraîner des modèles, sans réaliser d'étiquetage manuel ou automatique des données au préalable. Au lieu de cela, les modèles eux-mêmes trouvent les motifs cachés et les informations à partir des entrées données.

Les algorithmes les plus couramment utilisés dans l'apprentissage non supervisé comprennent : le clustering, la détection d'anomalies, les approches d'apprentissage des modèles de variables latentes [35].

### II. 1.1.3 Apprentissage Par Renforcement (RL)

Le RL est un type de technique d'apprentissage automatique qui permet à une machine d'apprendre dans un environnement interactif par essais et erreurs en utilisant les rétroactions de ses propres actions et expériences [36].

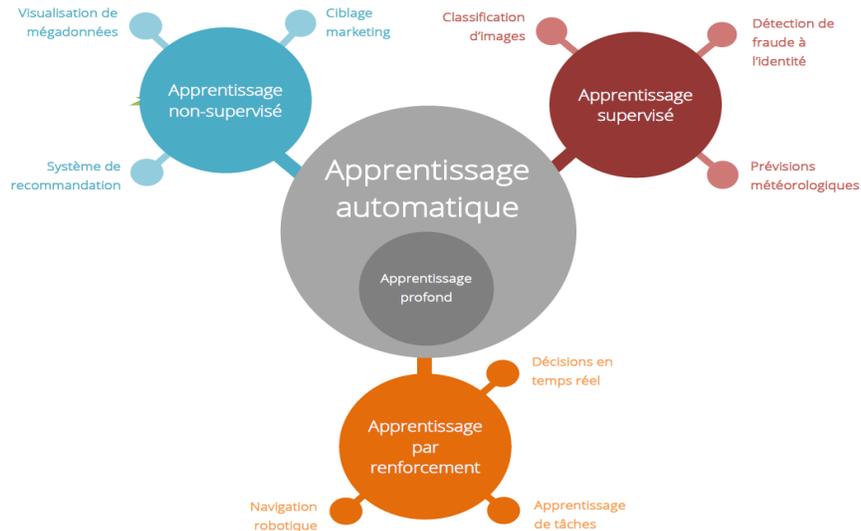


Figure II. 2 les différentes approches de l'apprentissage automatique [37]

## II.2 Réseaux de Neurones

Un réseau de neurones est un assemblage de constituants élémentaires interconnectés (appelés « neurones »), qui réalisent chacun un traitement simple mais dont l'ensemble en interaction fait émerger des propriétés globales complexes.

Les réseaux de neurones artificiel, inspirés par les réseaux de neurones biologiques, forme la base du ML. Ils viennent de l'essai de modélisation mathématique du cerveau humain. Il se basant principalement sur **le concept de neurone**. Les premiers travaux sur les réseaux de neurones publièrent par les neurologues Warren McCulloch et Walter Pitts dès la fin des années 1950.

### II.2.1 Le neurone biologique

Dans le cerveau humain, il existe des milliards de neurones qui ne sont pas indépendants les uns des autres, ils établissent entre eux des liaisons et forment des réseaux plus ou moins complexes.

Le neurone est une cellule composée :

- Corps cellulaire et d'un noyau qui traitent les informations reçues.
- Les dendrites qui est la partie réceptrice.
- L'axone qui est l'extension conducteur qui distribue des signaux.

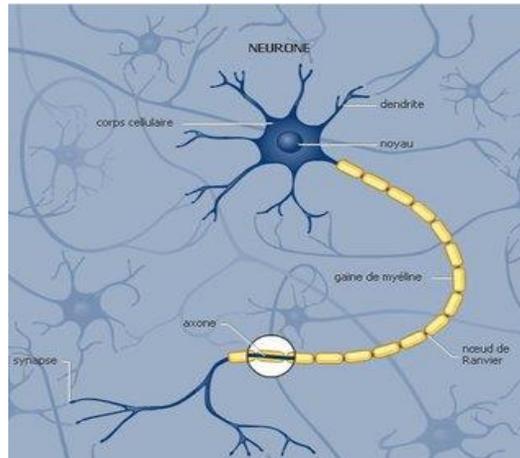


Figure II. 3 Le neurone biologique [38]

Les neurones sont reliés entre eux par l'intermédiaire des axones et des dendrites formant une jonction appelée **la synapse** qui permet donc aux neurones de communiquer entre eux.

Les informations proviennent d'autres neurones sous forme de signaux et sont reçues par les dendrites et envoyées au corps cellulaire où une sorte de sommations des signaux est faite. Quand la somme dépasse un certain seuil d'excitation, le neurone émet un signal électrique via l'axone. Contraire de cela, un message nerveux n'est pas émis [38], [39].

### II.2.2 Le Neurone Artificiel

Les réseaux de neurones artificiels sont des systèmes fortement connectés de processeurs élémentaires (neurones formels) fonctionnant en parallèle et en couches successives.

Un "neurone formel" (ou simplement "neurone") est une fonction algébrique non linéaire et bornée, dont la valeur dépend des paramètres appelés coefficients ou poids. Les variables de cette fonction sont souvent appelées "entrées" et la valeur de la fonction est appelée sa "sortie". A chacune de ces entrées est associée un poids  $w$  (weight en anglais) représentatif de la force de la connexion. Chaque processeur élémentaire calcule une sortie unique sur la

base des informations qu'il reçoit qui se ramifie ensuite pour alimenter un nombre variable de neurones dans la couche suivante [38], [40].

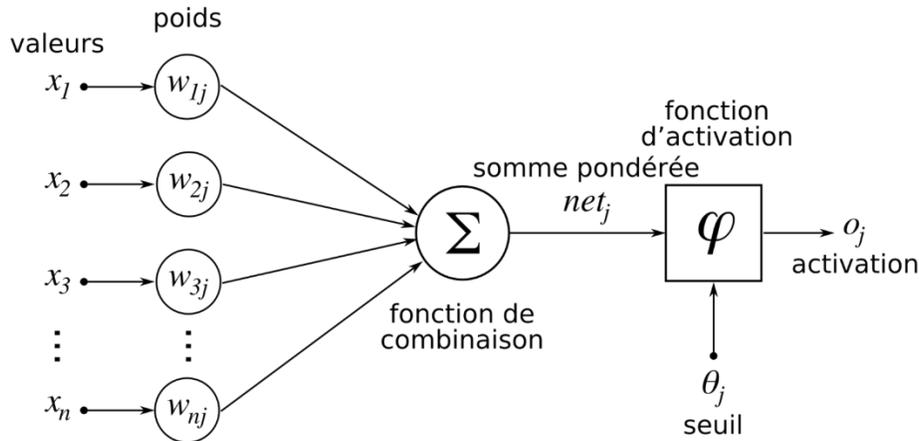


Figure II. 4 Schéma d'un neurone artificiel [41]

### Lien entre les neurones biologiques et neurones artificiels

Nous allons décrire la correspondance pour chaque élément composant le neurone biologique avec celle de neurone formel :

- ♣ Les dendrites : Correspond à un signal d'entrée unique  $T$  des  $x_i$  représentent les  $n$  vecteurs d'entrées provenant soit des entrées principales ou des sorties d'autres neurones.
- ♣ Les synapses : pondération de chaque élément en entrée avec les  $w_{ij}$  qui sont les poids synaptiques du neurone  $j$ . Ces poids pondèrent les entrées et peuvent être modifiés par apprentissage.

$$T = \sum w_i \cdot x_i$$

- ♣ Corps cellulaire : application d'une fonction d'activation  $A$  à la somme des entrées pondérées où  $A$  gère l'état du neurone. Selon le cas, le neurone est au repos si  $A \simeq -1$  ou  $A \simeq 0$  et il est excité si  $A \simeq 1$ .
- ♣ Les axones : c'est la transmission d'un signal de sortie  $s$  qui correspond à son état d'activation vers les autres neurones.

$$s = \sum_{i=1}^n w_{ij} \cdot x_i \pm b$$

Où  $b$  est le biais : entrée prend souvent les valeurs  $-1$  ou  $+1$  qui permet d'ajouter de la flexibilité au réseau [42].

### II.2.2.1 Les interconnexions d'un réseau de neurones

Les différentes connexions décrivent les topologies du réseau et ils incluent :

- **Le réseau monocouche (Perceptron de Rosenblatt) :** C'est un réseau simple qui se compose seulement d'une couche d'entrée et d'une couche de sortie.
- **Les réseaux multicouches :** C'est un réseau avec une ou plusieurs couches cachées entre l'entrée et la sortie. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches suivantes. Ils existent des types bouclés et non bouclés.

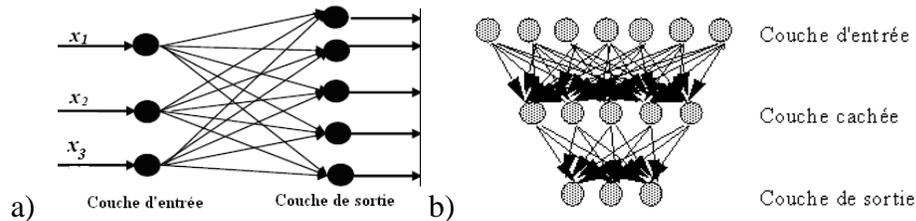


Figure II. 5 Schéma de réseau monocouche (a) et réseau multicouche (b) [40]

## II.3 Deep Learning

Deep Learning (DL), Apprentissage Profond en Fr, est un sous-ensemble de l'apprentissage automatique dont le concept de base réside dans la structure et la fonction du cerveau humain. DL a des choses en commun avec les réseaux de neurones artificiels, sauf qu'il a des développements qui exécutent des algorithmes plus rapidement et permettent un calcul plus approfondi. Il va plus loin que la connexion entre les données et les algorithmes puisqu'il permet à la machine d'apprendre et de progresser à cause de son expérience. Les algorithmes d'apprentissage en profondeur peuvent fonctionner avec une énorme quantité de données soit structurées ou non structurées [43].

Depuis l'introduction des réseaux de neurones en 1943, DL a évolué régulièrement au fil des ans, sa percée étant le développement d'un modèle de rétro propagation (back-propagation) continue où les bases du modèle sont attribuées à Henry J. Kelley en 1960 et en 1962, Stuart Dreyfus a proposé une version plus simple basée uniquement sur la règle de la chaîne [44].

**La rétro propagation** est une forme abrégée de "propagation arrière des erreurs" qui est un algorithme largement utilisé pour former des réseaux de neurones artificiels. C'est la méthode d'ajustement des poids d'un réseau de neurones en fonction du taux d'erreur (perte) obtenu à l'époque précédente par la règle de la chaîne. Il calcule efficacement une couche à la fois et généralise le calcul dans la règle delta. Un réglage approprié des poids garantit des taux d'erreur plus faibles, ce qui rend le modèle fiable en augmentant sa généralisation [45].

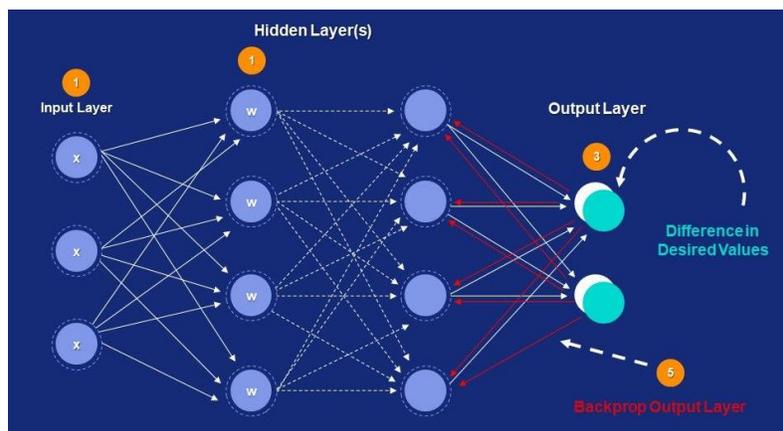


Figure II. 6 Démonstration de la retro propagation [45]

### II.3.1 Fonctionnement de l'Apprentissage Profond

La progression des calculs à travers les couches visibles (entrée et sortie) est connue sous le nom de **propagation vers l'avant (Feed-forward propagation)**. Les données sont traitées dans la couche d'entrée.

Dans la couche cachée, la somme pondérée est calculée et transmise comme entrée à la fonction d'activation où un biais est ajouté qui détermine si un neurone doit être déclenché ou non et la couche de sortie est l'endroit où la classification finale est faite.

Ensuite, la sortie du modèle est comparée à la sortie réelle. Après apprentissage, le modèle utilise la méthode de rétro propagation pour améliorer les performances du réseau et ensemble, la propagation vers l'avant et la rétro-propagation améliorent sa précision.

### Les applications de l'apprentissage profond

Voici quelques exemples de la façon dont DL a été intégré dans les produits et services utilisés dans notre vie quotidienne :

- A l'industrie de la santé, elle permet la reconnaissance d'images qui permet d'évaluer et d'analyser de nombreuses images en peu de temps, la reconnaissance automatique d'un cancer en imagerie médicale et la prédiction de certaines maladies.
- Aux renforcement de la loi et services financiers, elle peut analyser et apprendre des données transactionnelles pour identifier les schémas dangereux qui indiquent une activité criminelle possible.
- Généralement, elle peut être utilisée pour la génération de la musique, coloration des images, détection d'objet, service clientèle etc. [43].

### II.3.2 Deep Learning versus Machine Learning

L'apprentissage en profondeur fonctionne de différentes manières par rapport à l'apprentissage automatique. La principale différence étant l'extraction de caractéristiques qui est définie comme la sélection des variables avec lesquelles les utilisateurs travailleront pour influencer la prédiction (*Feature Extraction*). En ML, cette extraction est effectuée par des experts humains, mais en DL, elle est automatisée, ce qui réduit la dépendance vis-à-vis des experts humains. Par exemple, pour catégoriser un ensemble de photos de différents animaux de compagnie en "chat", "chien", "oiseau", etc., les algorithmes du DL peuvent déterminer les caractéristiques les plus importantes pour distinguer un animal d'un autre. Alors qu'en ML, cette hiérarchie de fonctionnalités est effectuée manuellement par l'homme.

Aussi, les algorithmes de Machine Learning vont traiter des données quantitatives et structurées (des valeurs numériques) alors que celles de Deep Learning traiteront des données volumiques et non-structurées, comme le son, le texte, l'image [46].

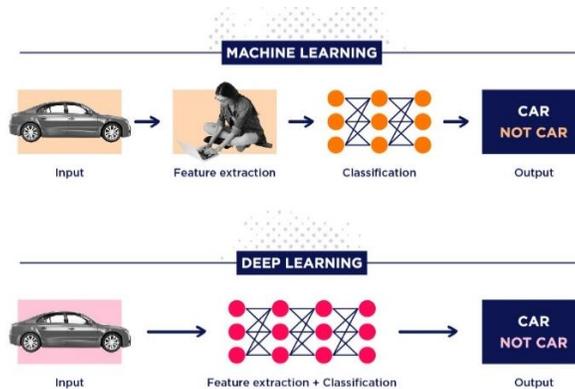


Figure II. 7 Processus de machine learning et deep learning [47]

### II.3.3 Types de réseaux de neurones profonds

Ils existent plusieurs types qui sont utilisés pour résoudre des problèmes ou des ensembles de données spécifiques et les plus populaires sont :

#### II.3.3.1 Réseau de neurone récurrent / Recurrent Neural Networks (RNN)

Ces sont les variantes des réseaux feed-forward (FF). La caractéristique principale des RNN est que les neurones internes à une couche peuvent être reliés entre eux. Ils peuvent également être reliés à eux-même, et à des neurones de couches précédentes en sens inverse.

Chacun des neurones des couches cachées de ce réseau reçoit une entrée avec un retard spécifique dans le temps. Il est utilisé pour accéder aux informations précédentes dans les itérations en cours. Par exemple, pour prédire le mot suivant dans une phrase, il faut d'abord connaître les mots précédemment utilisés et les calculs de ce modèle prennent en compte les informations historiques grâce au concept de mémoire interne qui l'aide à stocker les informations des entrées précédentes pour générer la sortie suivante. L'inconvénient de RNN est sa vitesse de calcul lente. Les RNNs sont couramment utilisés pour le sous-titrage d'images, l'analyse de séries chronologiques, le traitement du langage naturel, la reconnaissance de l'écriture manuscrite et la traduction automatique [46].

#### II.3.3.2 Les machines de Boltzmann restreintes / Restricted Boltzmann Machine (RBMs)

Développé par Geoffrey Hinton, Le RBM est le premier programme de DL à fonctionner sur une base de données non supervisée. Ce réseau de neurones fonctionne avec une couche visible et une couche invisible et il n'y a pas de connexions internes à l'intérieur de chaque

couche. Chaque unité visible est connectée à toutes les unités cachées et elles n'ont pas de nœuds de sortie.

Les RBM sont utilisés pour le filtrage, apprentissage des fonctionnalités, classification, détection des risques et analyse commerciale et économique [32], [46].

### II.3.3.3 Réseaux antagonistes génératifs / Generative Adversarial Networks (GANs)

Les GANs sont des algorithmes DL génératifs, conçu par Ian Goodfellow et al. en Juin 2014, qui créent de nouvelles instances de données qui ressemblent aux données d'apprentissage. Il comporte deux composants : un générateur, qui apprend à générer de fausses données, et un discriminateur, qui apprend à partir de ces fausses informations. Par exemple, un modèle formé de GAN sur des photographies pourra générer de nouvelles photographies qui semblent authentiques à l'œil humain. Quelques applications incluent : générez de nouvelles poses humaines, vieillissement du visage, super résolution, prédiction vidéo etc.

### II.3.3.4 Les réseaux de neurones convolutionnels / Convolutional Neural Networks (CNNs)

Les CNNs sont également connus sous le nom de ConvNets. C'est un type particulier de réseau de neurone vers l'avant, qui se base sur l'opération de convolution et consiste en plusieurs couches entre 3 et 150 couches ou plus, utilisé pour effectuer plusieurs transformations (LeCun et al. 2010).

Le premier CNN a été développé en 1988 et nommé LeNet d'après Yann LeCun. Ce n'est qu'en 1989 qu'il a été mis en lumière pour le traitement de données topologiques de type grille (images et données de séries chronologiques) (LeCun et al. 1989). La conception architecturale de CNN a été inspirée par les travaux de Hubel et Wiesel en 1962 et 1968 respectivement, qui suit la structure de base du cortex visuel de l'animal [38].

Les CNN sont des algorithmes utilisés pour comprendre le contenu des images, comme la classification et segmentation des images (identifier des images satellites, traiter des images médicales), détection d'objets (détecter des anomalies), reconnaissance faciale, reconnaissance vocale, jeu de dames [43], [48].

## Fonctionnement des CNN

Une architecture CNN typique comprend généralement des couches alternées de convolution, pooling et la couche de correction ReLU suivi d'une ou plusieurs couches entièrement connectées (Fully Connected) à la fin. Ils sont spécialement conçus pour la reconnaissance des images qui est représenté en 2 dimensions pour une image en niveaux de gris et en 3D pour une image colorée avec les trois couleurs fondamentales (Rouge, Verte, Bleue).

En entrée, une image est procurée sous la forme d'une matrice de pixels (**P**icture **E**lement) et est passe à travers une succession des filtres, créant de nouvelles images connu comme cartes de convolutions. Ils utilisent filtres convolutionnels, appelé *extracteur de features*, qui fait l'extraction des informations des images. Les couches précédentes détectent les bords, les filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local et les couches ultérieures peuvent détecter une partie des objets, même des objets complets, tels que des visages, ou d'autres formes géométriques complexes [49]. Les valeurs des cartes, après avoir été normalisée, sont concaténées dans un vecteur et envoyé comme entrée aux couches entièrement connectées où les valeurs de ce vecteur sont combinées pour classer l'image. Ces sont ensuite envoyé à la sortie qui est la dernière couche comportant un neurone par catégorie [50].

De suite, nous allons discuter des différentes couches des CNN groupé par leurs fonctionnalités.

### 1. La couche de convolution:

L'opération de convolution est l'un des éléments fondamentaux d'un réseau neuronal convolutif où un opération mathématique appelé une convolution, de laquelle les réseaux de neurones à convolution tiennent leur nom, est utilisé pour un filtrage afin de repérer la présence d'un ensemble de caractéristiques dans les images reçues en entrée.

Les paramètres de la couche convolutive sont constitués de filtres appelés noyaux (kernels). Le principe est de faire « glisser » ce(s) filtre(s) sur l'image, suivi d'une fonction d'activation non linéaire (sigmoïde, tanh, ReLU etc.) et cette opération résulte d'une carte d'activation connue comme *feature map* qui nous indique où se situent les caractéristiques dans l'image

: plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la caractéristique [49].

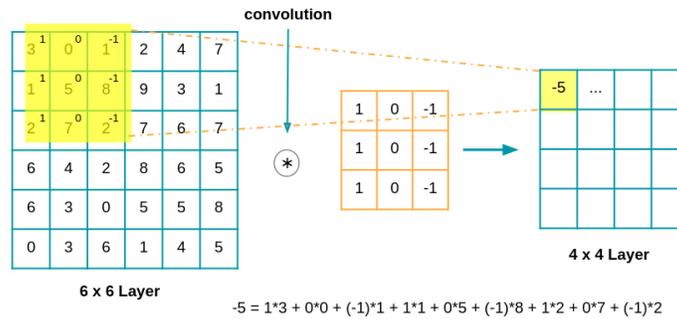


Figure II. 8 Couche de convolution avec un noyau 3x3 [51]

Un filtre peut être alors défini par une fenêtre carrée de dimension impaire (3x3, 5x5, 7x7), inférieur à l'image à convoluer où son déplacement est fait sur toutes les lignes et colonnes de l'image en remplaçant la valeur de chaque pixel de l'image par le résultat d'une transformation portant sur le pixel et ses voisins [52]. Le nombre de canaux dans un filtre dépend sur le nombre de canaux dans l'image d'entrée (un pour une image en noir et blanc, trois pour une image en couleur) et ses exemples incluent filtre Sobel et Prewitt pour la détection de contours, filtre Gaussien pour les bruits etc.

La dimension du résultat de pair (image, filtre) peut-être contrôler par ces trois hyper paramètres :

- ♣ Zero padding (la marge) P : Il augmente la taille d'une image en ajoutant des pixels remplis de zéros autour de sa bordure car l'application de la convolution à l'entrée réduit la taille de sortie, ce qui entraîne une perte d'informations.
- ♣ Stride (le pas) S : C'est un paramètre qui dénote le nombre de pixel par lesquels le filtre se déplace après chaque opération. Lorsque le pas est de 1, le filtre se déplace d'un pixel à la fois et lorsque le pas est de 2, le filtre saute de 2 pixels à la fois pendant son glissement. Cela produira des volumes de sortie plus petits dans l'espace.
- ♣ Profondeur de la couche K : Il représente le nombre de filtres utilisés dans l'opération de convolution, chacun recherchant une caractéristique différente (bords, couleurs) [49].

Avec N comme taille d'entrée, la quantité de la marge P, F comme taille de filtre et le pas comme S, la taille de sortie peut être calculée à l'aide de la fonction :

$$\frac{N + 2P - F}{S} + 1$$

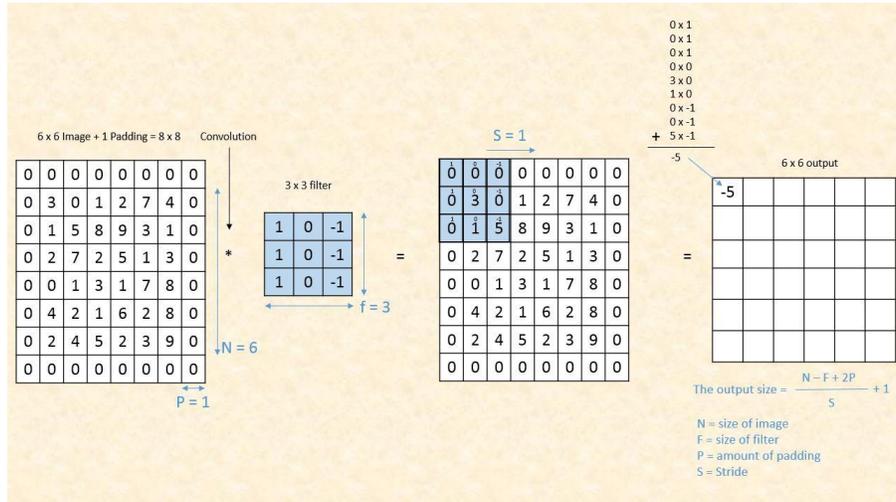


Figure II. 9 Convolution d'une image avec P=1, S=1, N = 6 et F= 3 [53]

## 2. La couche de pooling :

Le Pooling ou sous-échantillonnage est une méthode qui permet de réduire la taille d'une image tout en préservant les informations les plus importantes qu'elle contient et pour accélérer les calculs. Les deux méthodes les plus utilisées sont, soit la moyenne des valeurs de la zone (average pooling) ou on extrait uniquement la valeur maximale (max pooling). Max pooling est souvent utilisée par rapport à average pooling parce qu'elle maximise le poids des activations fortes. La forme la plus courante est avec une taille de filtre 2x2 et un pas de 2 [32].

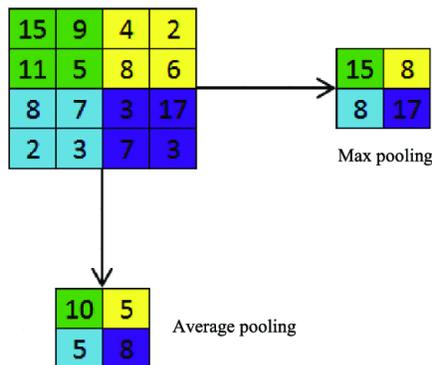


Figure II. 10 Deux types de sous-échantillonnage avec un pas de 2. [54]

**3. La couche de correction ReLU :**

La ReLU, acronyme de Rectified Linear Unit (unité linéaire rectifiée), est une fonction d'activation qui permet de remplacer les résultats négatifs par zéro, interprétée par la formule :  $f(x) = \max(0, x)$ .

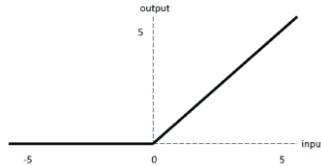


Figure II. 11 Graphe de la fonction ReLU [55]

La fonction d'activation est une fonction mathématique utilisée sur un signal qui produit le potentiel d'activation. Elle permet le passage d'information ou non si le seuil de stimulation est atteint. Aussi, elle mappe les valeurs résultantes entre 0 et 1 ou -1 à 1, etc. (selon la fonction) [32]. Quelques exemples incluent :

Sigmoide (Logistic)	$f(x) = \frac{1}{1 + e^{-x}}$	<p>The graph shows the Sigmoid Activation Function. The x-axis ranges from -10.0 to 10.0 with tick marks every 2.5 units. The y-axis ranges from 0.0 to 1.0 with tick marks every 0.2 units. The curve is an S-shape, starting near 0 for negative x, passing through 0.5 at x=0, and approaching 1.0 for positive x.</p>
Tanh	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	<p>The graph shows the Tanh Activation Function. The x-axis ranges from -10.0 to 10.0 with tick marks every 2.5 units. The y-axis ranges from -1.00 to 1.00 with tick marks every 0.25 units. The curve is an S-shape, starting near -1 for negative x, passing through 0 at x=0, and approaching 1 for positive x.</p>

Tableau II.1 Tableau des fonctions d'activation [55]

**4. La couche entièrement connectée/Fully connected layer :**

Cette couche est la couche de sortie finale pour les modèles CNN qui ont la carte des caractéristiques de la couche précédente, aplatie dans un vecteur, en entrée qui classe et identifie les images comme les résultats. Les neurones d'une couche entièrement connectée sont connectés avec toutes les sorties de la couche précédente qui explique le terme fully

connected et la dernière couche de cette architecture contient la même quantité de neurones de sortie que le nombre de classes à reconnaître [32]. Une fonction d'activation est appliquée aux valeurs résultantes de cette couche et au lieu d'utiliser ReLU, la fonction d'activation softmax est utilisée en raison de ses performances dans les classifications multi-classes.

**Softmax** est une fonction mathématique qui convertit un vecteur d'entrée de  $n$  valeurs réelles en un vecteur de probabilités, dont chacune est comprise entre 0 et 1, qui totalisent jusqu'à 1.

$$S(\vec{n})_i = \frac{e^{n_i}}{\sum_{j=1}^K e^{n_j}}$$

$S$  = softmax,  $\vec{n}$  = vecteur d'entrée,  $e^{n_i}$  = fonction exponentielle standard pour le vecteur d'entrée,  $K$  = nombre de classes dans le classificateur multi-classe,  $e^{n_j}$  = fonction exponentielle standard pour le vecteur de sortie [56].

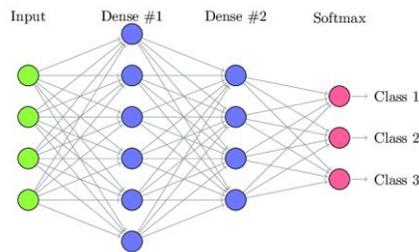


Figure II. 12 Exemple de l'application de softmax [57]

## 5. La couche de perte :

Le problème de l'apprentissage est décrit comme un problème d'optimisation. CNN utilise une stratégie d'optimisation pour minimiser l'erreur en utilisant une fonction de perte pour calculer cette erreur. Ceci est utilisé pour quantifier la performance du modèle, bonne ou mauvaise et de faire de bons prédictions [58].

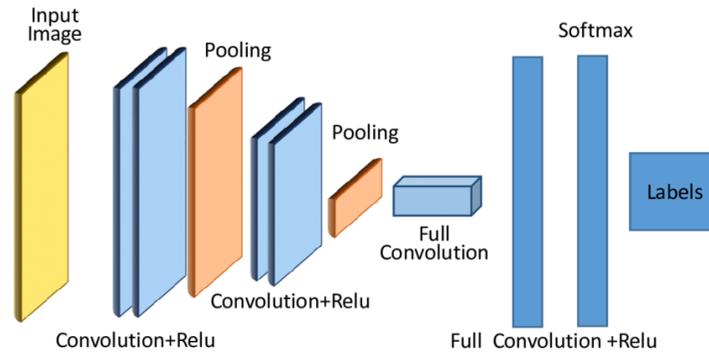


Figure II. 13 Les couches de CNN [59]

## Les architectures des CNN

Après avoir parlé des couches CNN, nous allons présenter certaines des différentes architectures en fonction de la façon dont leurs couches sont combinées. Ils incluent :

- **LeNet** : Elle se compose de cinq couches alternées de convolution et de pooling, suivies de deux couches entièrement connectées et une couche de sortie avec connexion gaussienne. Proposé par Yann LeCun et al. LeNet a 60,000 paramètres et Tanh comme son activation une fonction. C'était consacré à la reconnaissance des chiffres et célèbre pour la détection de signature manuscrite [49].

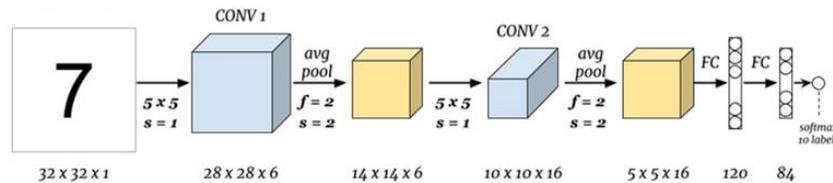


Figure II. 14 L'architecture de LeNet-5 [60]

- **AlexNet** : AlexNet a été proposé par Krizhevsky et al. et a montré des résultats révolutionnaires pour les tâches de classification et de reconnaissance d'images, remportant ainsi le ImageNet concours en 2012. Elle suit le modèle du LeNet, sauf qu'il était plus profond, plus grand et comportait plus de couches convolutionnelles empilés les uns sur les autres.

L'architecture se compose de 5 couches de convolution, trois max-pooling couches et 2 couches entièrement connectées. ReLU a été utilisé pour remplacer la fonction d'activation Tanh en LeNet [48].

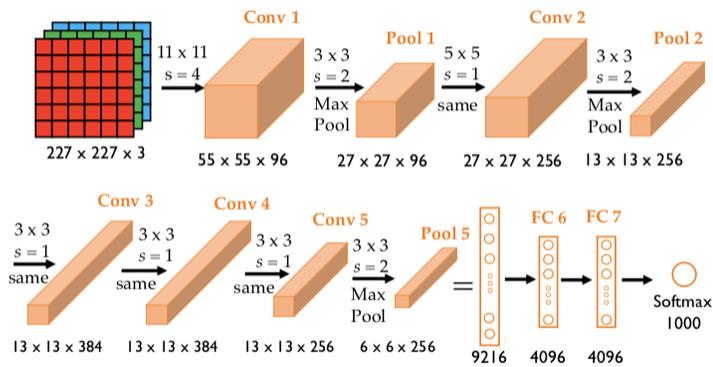


Figure II. 15 AlexNet Architecture [61]

- VGG :** VGG signifie Visual Geometry Group (Groupe de géométrie visuelle) et il existe VGG-16 ou VGG-19 composé de 16 et 19 couches convolutionnelles. Il a été introduit en 2014 par Karen Simonyan et Andrew Zisserman et sa principale contribution était de montrer que la profondeur du réseau est un composant essentiel pour obtenir une meilleure précision de reconnaissance ou de classification dans les CNN. Il est composé de 13/16 couches de convolution et de trois couches entièrement connectées, nécessitant 138 millions de poids pour classer l'image avec une taille de  $224 \times 224$ . VGG a remplacé les filtres  $11 \times 11$  et  $5 \times 5$  d'AlexNet par une pile de couches de filtres  $3 \times 3$  et a démontré que le placement simultané de filtres de petite taille ( $3 \times 3$ ) pouvait induire l'effet du filtre de grande taille ( $5 \times 5$  et  $7 \times 7$ ). L'utilisation de filtres de petite taille offre un avantage supplémentaire de faible complexité de calcul en réduisant le nombre de paramètres [49], [62].

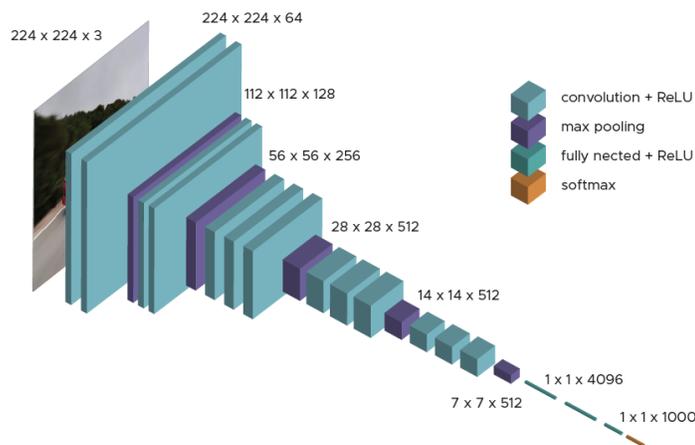


Figure II. 16 L'architecture de VGG [49]

- **GoogleNet/ Inception** : Jusqu'à présent, il existe trois versions des réseaux Inception, à savoir les versions 1, 2 et 3 et la première version est appelée GoogleNet. Il a été développé par une équipe de Google, a remporté le concours 2014-ILSVRC et est considéré comme la première utilisation de l'architecture CNN moderne, qui n'est pas composée uniquement de couches de convolution et de pooling, il a utilisé l'architecture d'Inception avec réductions dimensionnelles (Inception Module), c'est-à-dire une sorte de réseau dans le réseau (NIN). Le module d'Inception ignore les connexions dans le réseau formant un mini-module et ce module est répété dans tout le réseau.

Il a 22 couches de profondeur (27, y compris les couches de pooling), utilise 9 modules d'Inception qui sont empilés linéairement au total. Il utilise également l'average pooling globale, au lieu d'utiliser une couche entièrement connectée, à la fin du dernier module d'Inception et pour éviter que la partie médiane du réseau ne « s'éteigne », les auteurs ont introduit deux classificateurs auxiliaires. Cette architecture prend une image de taille 224 x 224 avec des canaux de couleur RVB et toutes les convolutions de cette architecture utilisent ReLU comme leurs fonctions d'activation. Ces ajustements de paramètres ont entraîné une diminution significative du nombre de paramètres de 138 millions à 4 millions de paramètres. Il existe également plusieurs versions de suivi au GoogleNet, plus récemment Inception-v4 [49], [63].

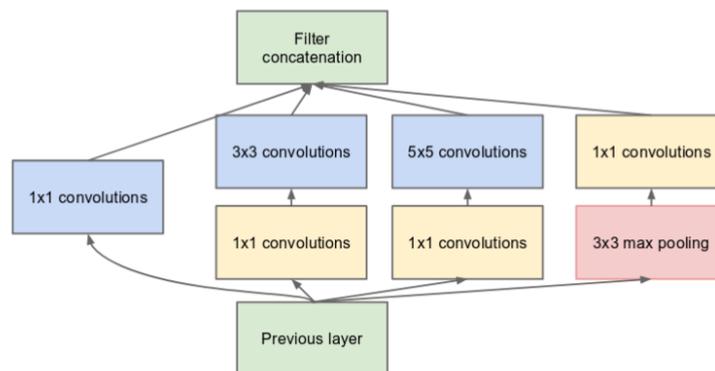


Figure II. 17 Module d'Inception avec réductions dimensionnelles [63]

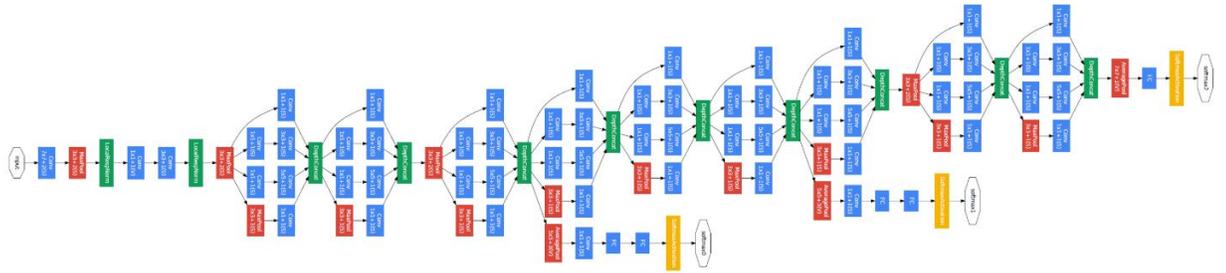


Figure II. 18 L'architecture de GoogleNet avec classificateurs auxiliaires [63]

- ResNet** : ResNet signifie Réseau Résiduel (Residual Network). Il a été proposé par He et al., et a remporté l'ILSVRC 2015. Il a de nombreuses variantes qui fonctionnent sur le même concept mais ont un nombre différent de couches et va aussi haut que 152 couches. ResNet est construit de blocs résiduels, empilés, chacun ayant deux  $3 \times 3$  couches de convolution. Il comporte des connexions de saut spéciales « où la sortie d'une couche est transmise à une couche plus profonde dans le réseau » qui est utilisé pour résoudre le problème de disparition du gradient pendant le processus d'apprentissage et utilisation de la normalisation par lots (Batch Normalization) après chaque couche de convolution. *La normalisation par lots est définie comme une technique pour améliorer la vitesse, la performance et la stabilité des réseaux de neurones artificiels.*

Sauf la couche entièrement connecté pour produire les 1000 classes, les ResNets n'ont pas de couches entièrement connectées afin de réduire le nombre de paramètres. Il est la première architecture qui a de meilleures performances que la performance humaine avec un taux d'erreur dans le top 5 inférieur à 5 % [48], [49].

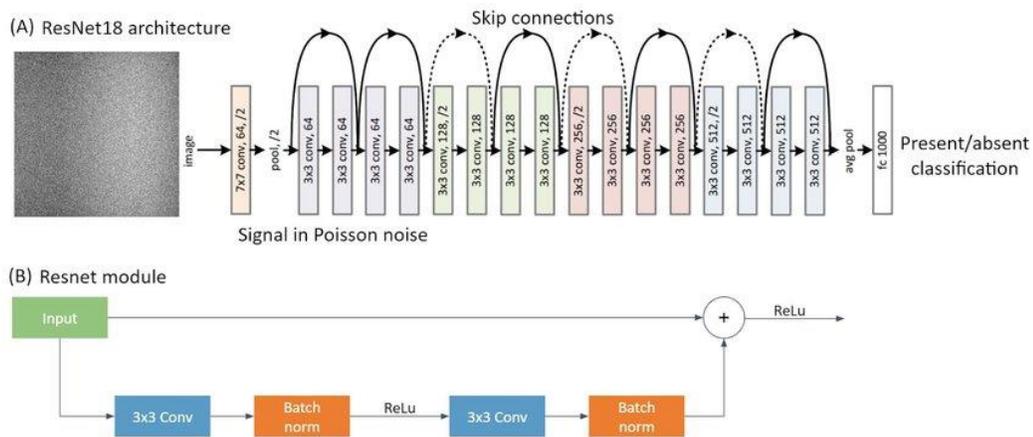


Figure II. 19 Architecture de ResNet-18 et Module de ResNet [64]

- EfficientNet** : EfficientNet a été proposé en 2019 par Tan et Le qui comporte huit modèles (modèles B0 à B7). EfficientNetB0, notre premier modèle, est un réseau qui prend une image d'entrée avec une dimension 224x224x3 et il a 237 couches. Le modèle extrait ensuite les caractéristiques à travers les couches en utilisant plusieurs couches convolutionnels utilisant un champ récepteur 3x3 et est basé sur les blocs résiduels de goulot d'étranglement inversés de MobileNetV2, en plus d'autres blocs. Il est entraîné sur plus d'un million d'images d'ImageNet. Ce peut classer les images en 1000 catégories d'objets, telles que le clavier, la souris, le crayon et de nombreux animaux [65].

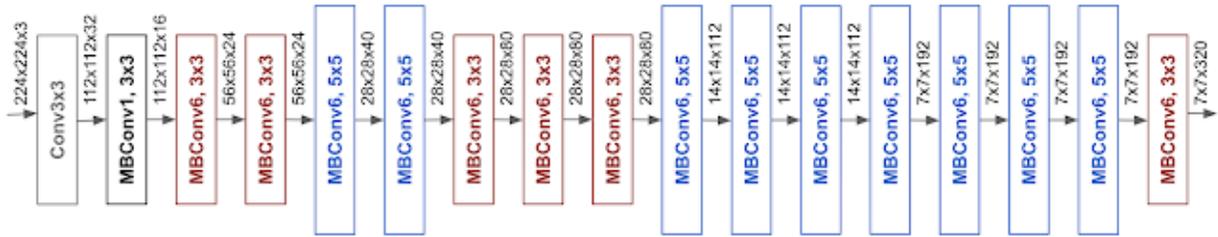


Figure II. 20 Architecture d'EfficientNetB0 [66]

Les architectures de CNN sont entraînées sur un grand ensemble des images général (particulièrement ImageNet) où les images biométriques fœtales ne sont pas incluses alors nous allons utiliser le concept de **Transfer Learning (Apprentissage par Transfert)** car l'apprentissage d'un modèle à partir de zéro nécessite un grand ensemble de données et beaucoup de temps.

Dans l'apprentissage en profondeur, l'apprentissage par transfert est une technique par laquelle les connaissances acquises à partir d'un modèle de réseau neuronal préalablement formé avec un grand ensemble de données sont utilisées pour une tâche similaire avec un ensemble de données plus petit. Cela se fait en gelant les poids du modèle pré-entraîné afin qu'ils ne soient pas mis à jour pendant l'entraînement du modèle cible et seules les dernières couches sont entraînées, les hyper paramètres sont ajustés et si nécessaire, d'autres couches sont dégelées pour faire une prédiction [67].

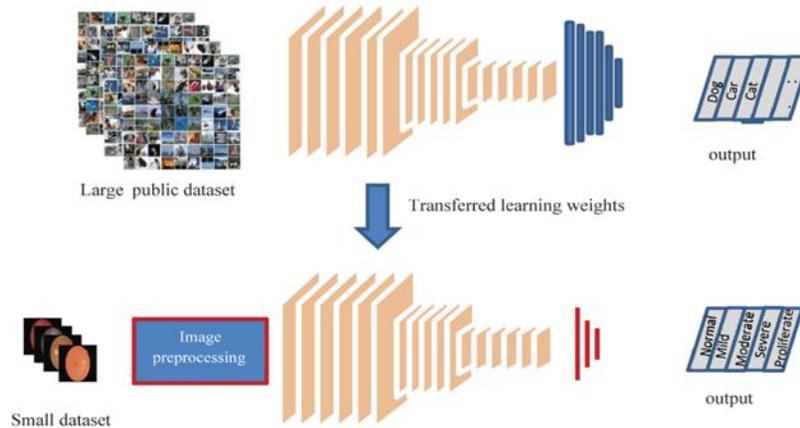


Figure II. 21 Transfer Learning [68]

## II.4 Conclusion

Nous avons dédié ce chapitre aux techniques de classifications des images qui incluent l'apprentissage automatique et ses évolutions, le réseau de neurone artificielle qui se base sur la notion d'un neurone biologique. Ces techniques peuvent être utilise pour résoudre les problèmes, soit dans le domaine médical ou la vie quotidienne car ils ont la capacité d'extraire les caractéristiques des images, prédire-les et les classifier.

Nous avons aussi présenté le réseau de neurone profond et ses différents types. Ensuite, nous avons détaillé le réseau de neurone convolutionnels et ses différentes architectures incluent EfficientNetB0, InceptionV3 et ResNet50.

# CHAPITRE III

---

## CLASSIFICATION DES IMAGES BIOMETRIQUES FŒTALES

### III. Introduction

Nous allons dédier ce chapitre à l'application de différentes architectures, tels que EfficientNetB0, ResNet50 et InceptionV3, à une base de données d'images de biométrie fœtale pour leurs classifications.

### III. 1 Les outils, logiciels et les libraires utilisés

#### III. 1.1 Python

Python est un langage de programmation à usage général populaire créé par Guido van Rossum et publié en 1991. Il est de haut niveau et utilise des règles de syntaxe pour écrire ce qui est considéré comme du code Python valide et un logiciel interpréteur qui lit le code source et exécute ses instructions. Son langage est scripté orienté objet, a intégré des types de données de haut niveau (listes, dictionnaires, etc.), il est interactif et très lisible. Il a une syntaxe simple similaire à la langue anglaise avec l'influence des mathématiques. Python fonctionne sur différentes plates-formes (Windows, Mac, Linux, Raspberry Pi, etc.) et ses bibliothèques sont disponibles sans charges pour la majorité des plateformes et peuvent être redistribués gratuitement. Il est employé dans le développement Web, la science des données, la création de prototypes de logiciels, etc [69].



Figure III. 1 Python Logo [70]

#### III. 1.2 TensorFlow

TensorFlow est une plate-forme open source de bout en bout, une bibliothèque pour le calcul numérique et les tâches de réseau de neurones avec plusieurs couches développées par Google et publiée en 2015. Il s'agit d'une boîte à outils permettant de résoudre des problèmes mathématiques extrêmement complexes avec aisance. En acceptant les entrées sous la forme d'un tableau multidimensionnel appelé Tensor, TensorFlow vous permet de créer des graphiques et des structures de flux de données pour spécifier la manière dont les données

se déplacent dans un graphique. Il vous permet de créer un organigramme des opérations pouvant être effectuées sur ces entrées, qui se déplacent dans un sens et sort dans l'autre. Elle permet aux chercheurs de développer des architectures d'apprentissage expérimentales et de les transformer en logiciels. TensorFlow est principalement utilisé pour : la création et la prédiction, les applications textuelles, la reconnaissance vocale/sonore et reconnaissance d'images [71].



Figure III. 2 TensorFlow [72]

### III.1.3 Keras

Keras est une API (Application Programming Interface - interface de programmation d'applications) d'apprentissage en profondeur écrite en Python, fonctionnant au-dessus de la plate-forme d'apprentissage automatique TensorFlow qui fournit un moyen de résumer un modèle en incluant :

- Les couches et leurs ordres dans le modèle.
- La forme de sortie de chaque couche.
- Le nombre de paramètres (poids) dans chaque couche.
- Le nombre total de paramètres (pondérations) dans le modèle.

Les structures de données de Keras sont des couches, des modèles, des API de rappels (Callbacks API comme Model Checkpoint et TensorBoard), des optimiseurs (SGD, Adam, Adadelta, Nadam), des métriques (Accuracy metrics, Regression metrics, Classification metrics based on True /False positives & negatives, Image segmentation metrics), des pertes (Regression losses), des utilitaires (Python & NumPy utilities, Backend utilities) et des applications Keras (Xception, EfficientNet, MobileNet, DenseNet) [73].



Figure III. 3 Logo de Keras [73]

### III. 1.4 Jupyter Notebook and Google Colaboratory

Jupyter Notebook est l'application Web originale pour créer et partager (par e-mail, Dropbox, GitHub) des documents informatiques qui permet d'éditer et d'exécuter des documents via un navigateur Web pour produire des sorties interactives telles que HTML, images, vidéos, etc. Il peut être exécuté sur un bureau local ne nécessitant aucun accès à Internet ou peut être installé sur un serveur distant et accessible via Internet. Ça aussi prend en charge plus de 40 langages de programmation, dont Python, Julia et Scala [74].



Figure III. 4 Jupyter and Colab logo [75]

Jupyter est le projet open source sur lequel Colab est basé. Colab, ou 'Colaboratory', est un service de bloc-notes Jupyter hébergé entièrement dans le cloud, un produit de Google Research, qui vous permet d'écrire et d'exécuter Python dans votre navigateur, sans configuration requise, accès gratuit aux GPU et facilité partager sans avoir à télécharger, installer ou exécuter quoi que ce soit. Il vous permet également d'utiliser et de partager des blocs-notes avec d'autres, sont stockés dans Google Drive ou peuvent être chargés à partir de GitHub [76].

## III. 2 Matériels utilisés

Le matériel employé est un pc portable Acer i5-8250U CPU 2.30 GHZ avec RAM de taille 8 GB, Système d'exploitation Windows 10 Pro 64 bit.

## III.3 Data sets

Nous allons utiliser 47 dossiers d'images biométriques fœtales ultrasonores à partir des 2<sup>ème</sup> et 3<sup>ème</sup> trimestres, chaque dossier contenant 5 images ; circonférence de la tête, circonférence abdominale, coupe du thorax, longueur du fémur et liquide amniotique. Ces images ont été acquises à l'EPH Kouba et à la Clinique des Lilas en collaboration avec Dr Benamer Lamia

Nawel à l'aide d'un Voluson S8 (GE Medical Systems, Zipf, Austria) et d'un transducteur courbe avec une gamme de fréquences de 3 à 7,5 MHz.

### III.4 Création de classes

À partir de notre dossier d'images, nous avons regroupé les images selon leur classe. Ensuite, nous avons regroupé ces classes en apprentissage (training), et testing.

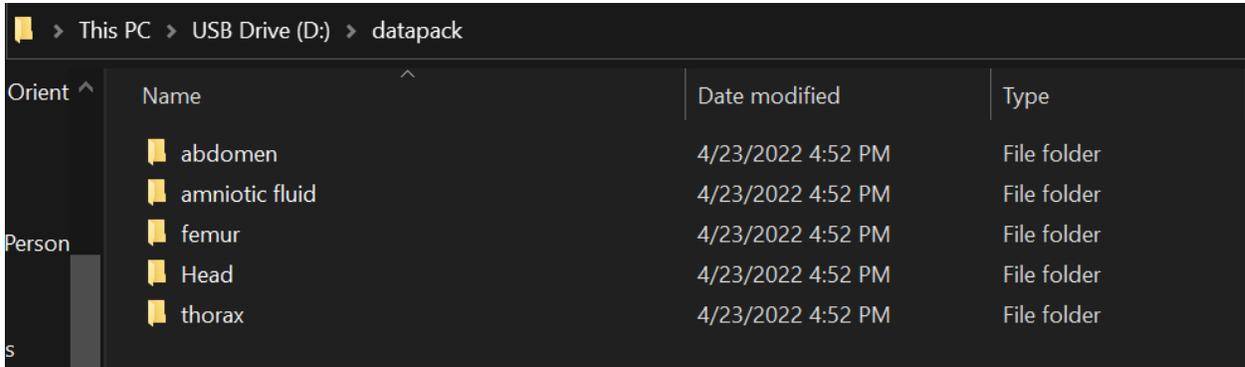


Figure III. 5 Les cinq classes des images (Head : Tête, Abdomen : Abdomen, Thorax : Thorax, Femur : Fémur et Amniotic fluid : Liquide amniotique)



Figure III. 6 Exemples des images de chaque classe avec 1 : Tête, 2 : Abdomen, 3 : Thorax, 4 : Fémur et 5 : Liquide amniotique.

### III.5 Les mesures de performance

#### III.5.1 Matrice de Confusion

C'est un outil de mesure qui visualise et résume les performances des modèles de classification à 2 classes ou plus. Il compare les données réelles pour une variable désirée à celles prédites par un modèle et elle est indispensable pour définir les différentes métriques de classification [77].

		Classe prédite	
		+	-
Classe réelle	+	True Positives, TP (Vrais Positifs, VP)	False Negative, FN (Faux Négatifs, FN)
	-	False Positives, FP (Faux Positifs, FP)	True Negatives, TN (Vrais Négatifs, VN)

Tableau III.1 Matrice de Confusion

### III.5.2 Accuracy (Taux de classification)

C'est une métrique pour évaluer les performances du modèle dans toutes les classes. Il est calculé comme le rapport entre le nombre de prédictions correctes et le nombre total de prédictions [77].

$$Accuracy = \frac{VP + VN}{Nombre\ Total}$$

### III.5.3 Recall

C'est également appelé sensibilité (sensitivity) et mesure la capacité du modèle à détecter les cas positifs.

$$Recall = \frac{VP}{VP + FN}$$

### III.5.4 Précision

C'est également appelé Positive Predictive Value. Elle correspond au taux de prédictions correctes parmi les prédictions positives [77].

$$Précision = \frac{VP}{VP + FP}$$

### III.5.5 F1-Score

C'est une mesure de la précision d'un modèle sur un ensemble de données qui est définie comme la moyenne harmonique de la précision et du recall [78].

$$F1-score = 2 \times \frac{précision \times recall}{précision + recall}$$

### III.6 Forme de notre modèle

Nous allons modifier certains hyper paramètres des modèles : ResNet, EfficientNet et Inception. Utiliser ensuite ces modèles sur notre ensemble de données pour cette tâche de classification d'images. En utilisant Transfer Learning, nous avons changé les trois dernières couches en les remplaçant par les couches de globalaveragepooling2D, dropout avec un taux de 0.5 et dense pour les 5 class.

#### III.6.1 Architecture du modèle 1 (EfficientNetB0)

```
B0 = tf.keras.applications.efficientnet.EfficientNetB0()
B0.summary()
```

block7a_project_conv (Conv2D)	(None, 7, 7, 320)	368640	['block7a_se_expand[0][0]']
block7a_project_bn (Batch Normalization)	(None, 7, 7, 320)	1280	['block7a_project_conv[0][0]']
top_conv (Conv2D)	(None, 7, 7, 1280)	409600	['block7a_project_bn[0][0]']
top_bn (Batch Normalization)	(None, 7, 7, 1280)	5120	['top_conv[0][0]']
top_activation (Activation)	(None, 7, 7, 1280)	0	['top_bn[0][0]']
avg_pool (GlobalAveragePooling2D)	(None, 1280)	0	['top_activation[0][0]']
top_dropout (Dropout)	(None, 1280)	0	['avg_pool[0][0]']
predictions (Dense)	(None, 1000)	1281000	['top_dropout[0][0]']

Figure III. 7 Configuration d'EfficientNetB0

block7a_se_reshape (Reshape)	(None, 1, 1, 1152)	0	['block7a_se_squeeze[0][0]']
block7a_se_reduce (Conv2D)	(None, 1, 1, 48)	55344	['block7a_se_reshape[0][0]']
block7a_se_expand (Conv2D)	(None, 1, 1, 1152)	56448	['block7a_se_reduce[0][0]']
block7a_se_excite (Multiply)	(None, 5, 5, 1152)	0	['block7a_activation[0][0]', 'block7a_se_expand[0][0]']
block7a_project_conv (Conv2D)	(None, 5, 5, 320)	368640	['block7a_se_excite[0][0]']
block7a_project_bn (Batch Normalization)	(None, 5, 5, 320)	1280	['block7a_project_conv[0][0]']
top_conv (Conv2D)	(None, 5, 5, 1280)	409600	['block7a_project_bn[0][0]']
top_bn (Batch Normalization)	(None, 5, 5, 1280)	5120	['top_conv[0][0]']
top_activation (Activation)	(None, 5, 5, 1280)	0	['top_bn[0][0]']
global_average_pooling2d_2 (GlobalAveragePooling2D)	(None, 1280)	0	['top_activation[0][0]']
dropout_1 (Dropout)	(None, 1280)	0	['global_average_pooling2d_2[0][0]']
dense_1 (Dense)	(None, 5)	6405	['dropout_1[0][0]']

Figure III. 8 Configuration d'Efficient après Transfer Learning

#### III.6.2 Architecture du modèle 2 (ResNet50)

Pour le deuxième modèle, on a employé le réseau ResNet50 (50 couches)

```

net1 = tf.keras.applications.resnet.ResNet50()

net1.summary()

```

conv5_block3_2_relu (Activation)	(None, 7, 7, 512)	0	['conv5_block3_2_bn[0][0]']
conv5_block3_3_conv (Conv2D)	(None, 7, 7, 2048)	1050624	['conv5_block3_2_relu[0][0]']
conv5_block3_3_bn (BatchNormalization)	(None, 7, 7, 2048)	8192	['conv5_block3_3_conv[0][0]']
conv5_block3_add (Add)	(None, 7, 7, 2048)	0	['conv5_block2_out[0][0]', 'conv5_block3_3_bn[0][0]']
conv5_block3_out (Activation)	(None, 7, 7, 2048)	0	['conv5_block3_add[0][0]']
avg_pool (GlobalAveragePooling2D)	(None, 2048)	0	['conv5_block3_out[0][0]']
predictions (Dense)	(None, 1000)	2049000	['avg_pool[0][0]']

Figure III. 9 Configuration de ResNet

```

conv5_block3_3_conv (Conv2D) (None, 7, 7, 2048) 1050624 ['conv5_block3_2_relu[0][0]']
conv5_block3_3_bn (BatchNormalization) (None, 7, 7, 2048) 8192 ['conv5_block3_3_conv[0][0]']
conv5_block3_add (Add) (None, 7, 7, 2048) 0 ['conv5_block2_out[0][0]', 'conv5_block3_3_bn[0][0]']
conv5_block3_out (Activation) (None, 7, 7, 2048) 0 ['conv5_block3_add[0][0]']
global_average_pooling2d (GlobalAveragePooling2D) (None, 2048) 0 ['conv5_block3_out[0][0]']
dropout (Dropout) (None, 2048) 0 ['global_average_pooling2d[0][0]']
dense (Dense) (None, 5) 10245 ['dropout[0][0]']

```

Figure III. 10 Configuration de ResNet après Transfer Learning

### III.6.3 Architecture du modèle 3 (Inception\_V3)

```

batch_normalization_93 (BatchNormalization) (None, 8, 8, 192) 576 ['conv2d_93[0][0]']
activation_85 (Activation) (None, 8, 8, 320) 0 ['batch_normalization_93[0][0]']
mixed9_1 (Concatenate) (None, 8, 8, 768) 0 ['activation_85[0][0]', 'activation_88[0][0]']
concatenate_1 (Concatenate) (None, 8, 8, 768) 0 ['activation_91[0][0]', 'activation_92[0][0]']
activation_93 (Activation) (None, 8, 8, 192) 0 ['batch_normalization_93[0][0]']
mixed10 (Concatenate) (None, 8, 8, 2048) 0 ['activation_85[0][0]', 'mixed9_1[0][0]', 'concatenate_1[0][0]', 'activation_93[0][0]']
avg_pool (GlobalAveragePooling2D) (None, 2048) 0 ['mixed10[0][0]']
predictions (Dense) (None, 1000) 2049000 ['avg_pool[0][0]']

```

Figure III. 11 Configuration d'InceptionV3

```

batch_normalization_187 (Batch Normalization) (None, 5, 5, 192) 576 ['conv2d_187[0][0]']
activation_179 (Activation) (None, 5, 5, 320) 0 ['batch_normalization_179[0][0]']
mixed9_1 (Concatenate) (None, 5, 5, 768) 0 ['activation_181[0][0]', 'activation_182[0][0]']
concatenate_3 (Concatenate) (None, 5, 5, 768) 0 ['activation_185[0][0]', 'activation_186[0][0]']
activation_187 (Activation) (None, 5, 5, 192) 0 ['batch_normalization_187[0][0]']
mixed10 (Concatenate) (None, 5, 5, 2048) 0 ['activation_179[0][0]', 'mixed9_1[0][0]', 'concatenate_3[0][0]', 'activation_187[0][0]']
global_average_pooling2d_3 (GlobalAveragePooling2D) (None, 2048) 0 ['mixed10[0][0]']
dropout_1 (Dropout) (None, 2048) 0 ['global_average_pooling2d_3[0][0]']
dense_1 (Dense) (None, 5) 10245 ['dropout_1[0][0]']
    
```

Figure III. 12 Configuration d'InceptionV3 après Transfer Learning

### III.7 Résultats et Discussion

#### III.7.1 Epoque de 12 et la classe Categorical Crossentropy comme perte

Les résultats ci-dessous concernent le taux de classification et le F1- score des modèles utilisant Adam comme optimiseur :

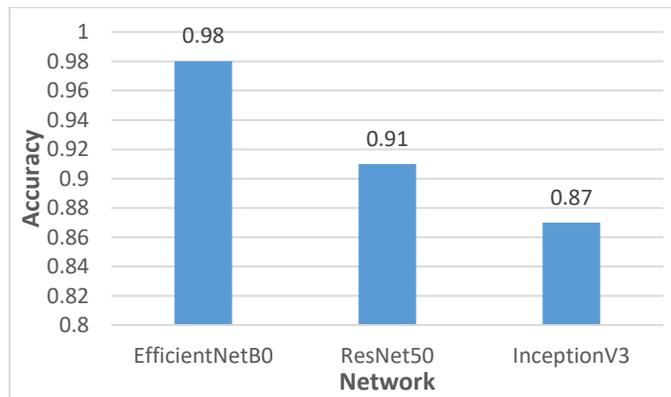


Figure III. 13 Histogramme du taux de classification des trois modèles avec Optimiseur Adam à Epoque 12

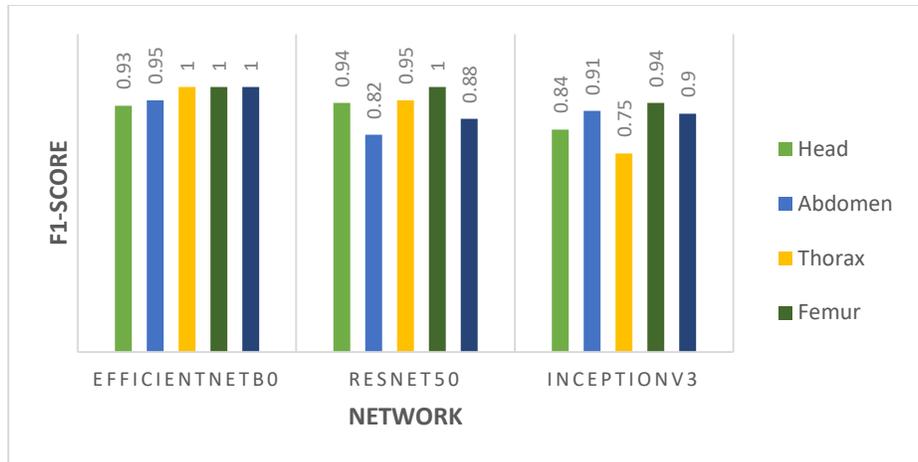


Figure III. 14 Histogramme de F1-Score avec Adam

A) Ensuite, nous avons changés l’optimiseur et utilisés Nadam :

- Le taux de classification d’EfficientNetB0 est restée la même à 0.98, celle de ResNet50 était 0.96 et pour Inception, il était 0.98.
- Les résultats de F1- score sont :

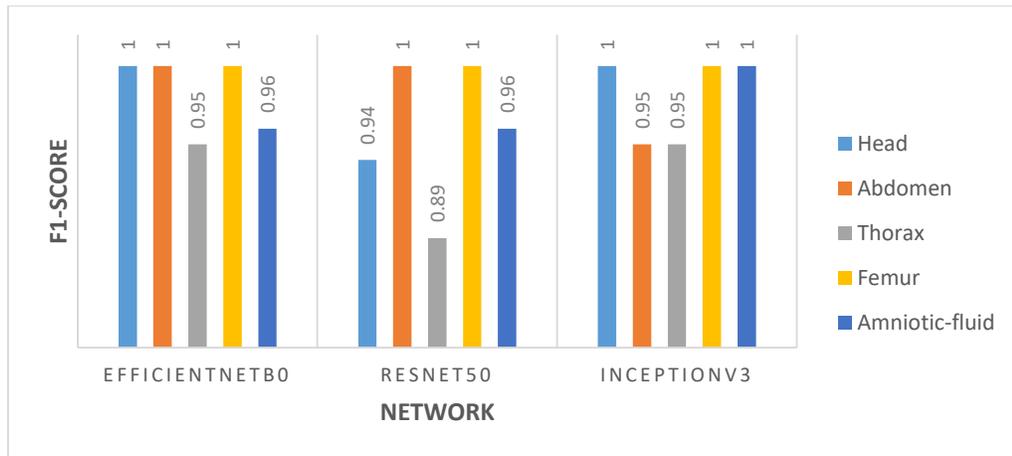


Figure III. 15 Histogramme de F1-Score avec Optimiseur Nadam

B) Ensuite, nous avons changés l’optimiseur et utilisés SGD :

- Le taux de classification d’EfficientNetB0 était 0.87, celle de ResNet50 était 0.96 et pour InceptionV3, c’était 0.94.
- Les résultats de F1-Score sont :

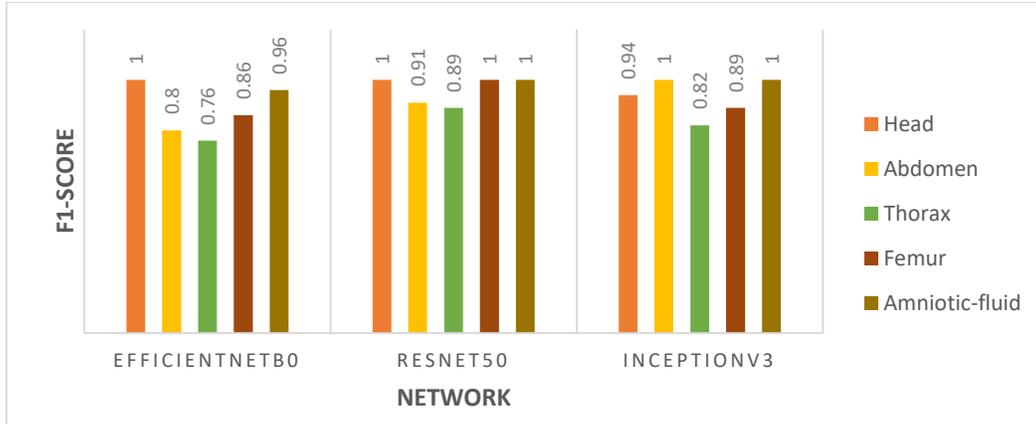


Figure III. 16 Histogramme de F1-Score avec Optimiseur SGD

**Remarque :**

À cette époque, le taux de classification d'EfficientNetB0 était la plus élevée (98 %) avec Adam et Nadam et la plus faible avec SGD, ResNet50 était la plus élevée (96 %) avec SGD et Nadam mais faible avec Adam et InceptionV3 était la plus élevée (94 %) avec Nadam, suivi de SGD puis Adam.

III.7.2 Epoque de 14 et la classe Categorical Crossentropy comme perte

A) Les résultats ci-dessous concernent le taux de classification et le F1- score des modèles utilisant Adam comme optimiseur :

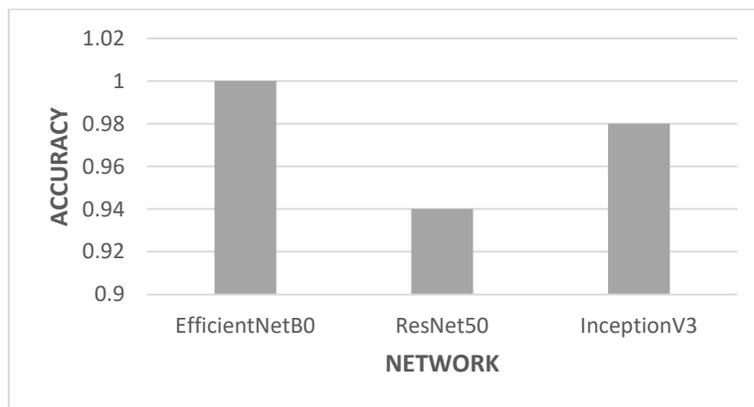


Figure III. 17 Histogramme du taux de classification des trois modèles avec Optimiseur Adam à Epoque 14

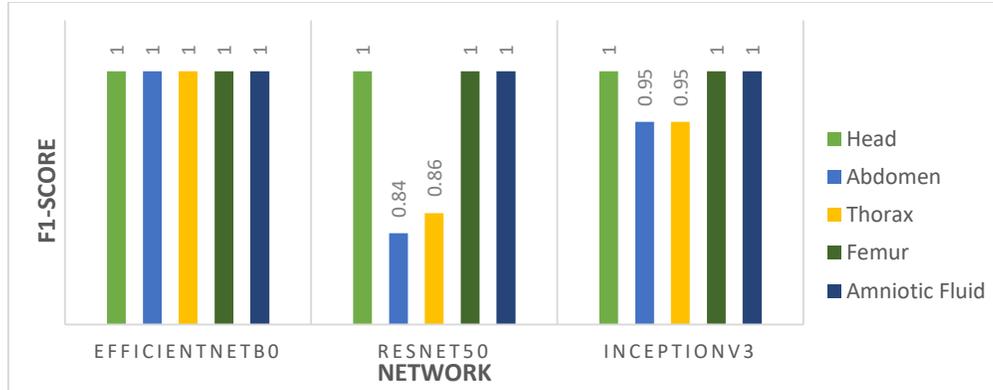


Figure III. 18 Histogramme de F1-Score avec Adam

B) Ensuite, nous avons changés l’optimiseur et utilisés Nadam :

- Le taux de classification d’EfficientNetB0 est restée la même à 0.98, celle de ResNet50 était 0.96 et pour Inception, il était 0.98.
- Les résultats de F1- score sont :

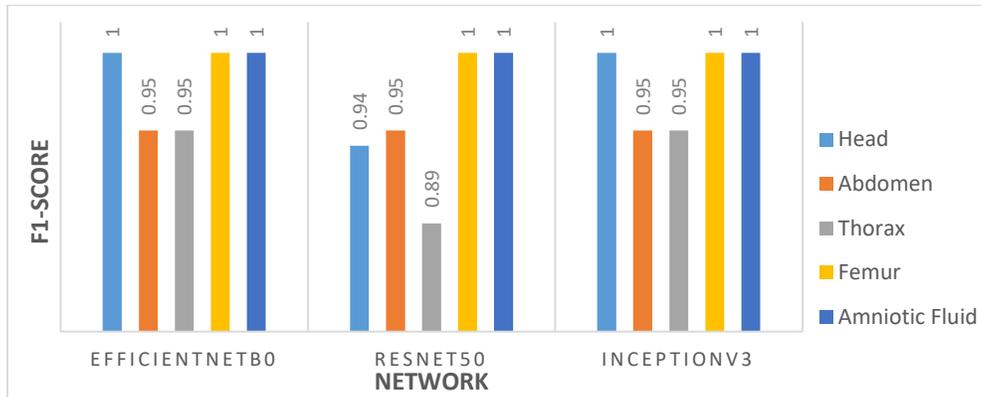


Figure III. 19 Histogramme de F1-Score avec Optimiseur Nadam

C) Ensuite, nous avons changés l’optimiseur et utilisés SGD :

- Le taux de classification d’EfficientNetB0 était 0.89, celle de ResNet50 était 0.96 et pour InceptionV3, c’était 0.96.
- Les résultats de F1-Score sont :

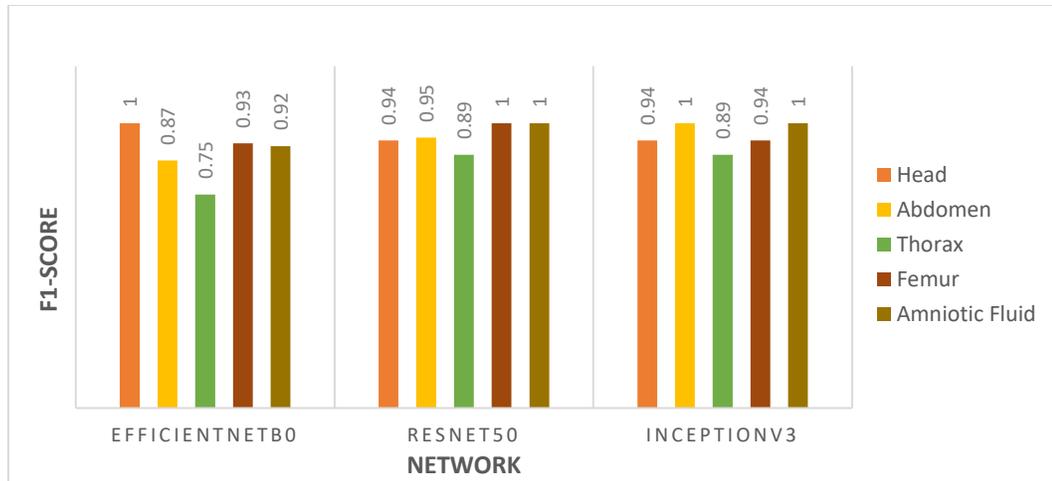


Figure III. 20 Histogramme de F1-Score avec Optimiseur SGD

**Remarque :**

À cette époque, le taux de classification d'EfficientNetB0 était la plus élevée (100 %) avec Adam, suivi de Nadam et la plus faible avec SGD, ResNet50 était la plus élevée (96 %) avec SGD et Nadam mais faible avec Adam et InceptionV3 était la plus élevée (98 %) avec Nadam et Adam et la plus faible avec SGD

III.7.3 Epoque de 15 et la classe Categorical Crossentropy comme perte

A) Les résultats ci-dessous concernent le taux de classification et le F1- score des modèles utilisant Adam comme optimiseur :

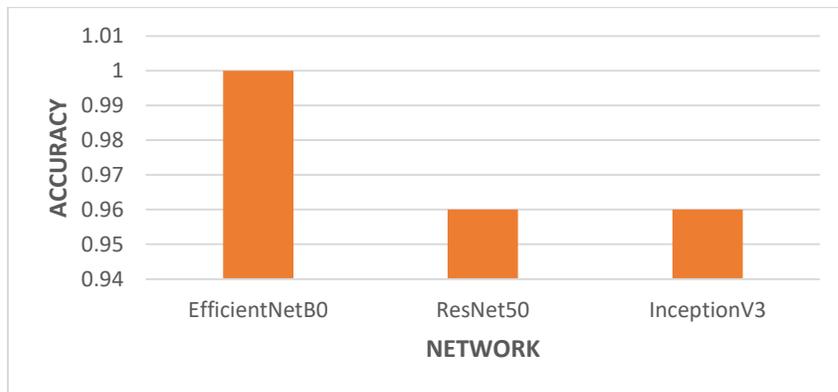


Figure III. 21 Histogramme du taux de classification avec Optimiseur Adam à Epoque 15

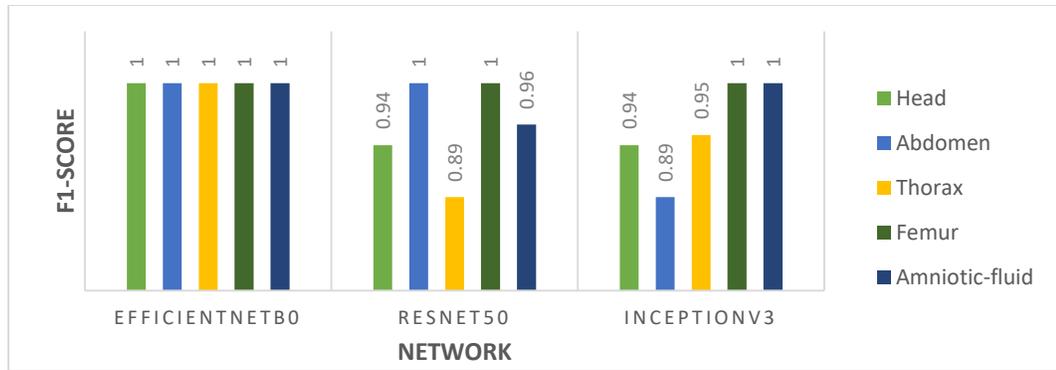


Figure III. 22 Histogramme de F1-Score à Epoque 15 avec Adam

B) Ensuite, nous avons changés l’optimiseur et utilisés Nadam :

- Le taux de classification d’EfficientNetB0 était 1.00, celle de ResNet50 était 0.96 et pour Inception, il était 0.96
- Les résultats de F1- score sont :

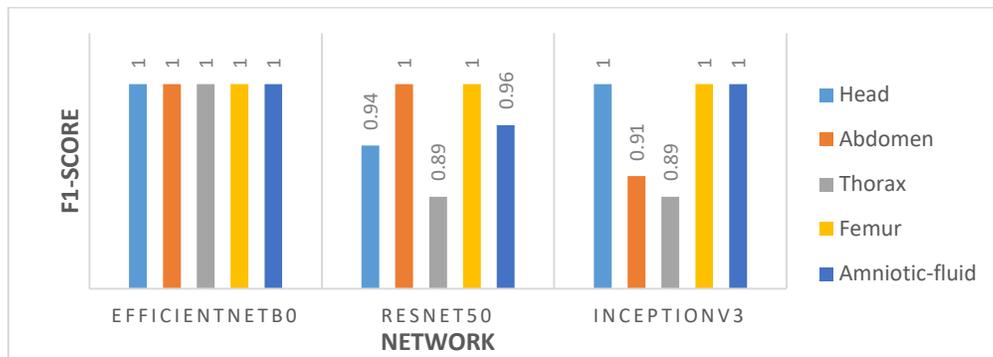


Figure III. 23 Histogramme de F1-Score à Epoque 15 avec Nadam

C) Ensuite, nous avons changés l’optimiseur et utilisés SGD.

- Le taux de classification d’EfficientNetB0 était 0.91, celle de ResNet50 était 0.98 et pour InceptionV3, c’était 0.96.
- Les résultats de F1-Score sont :

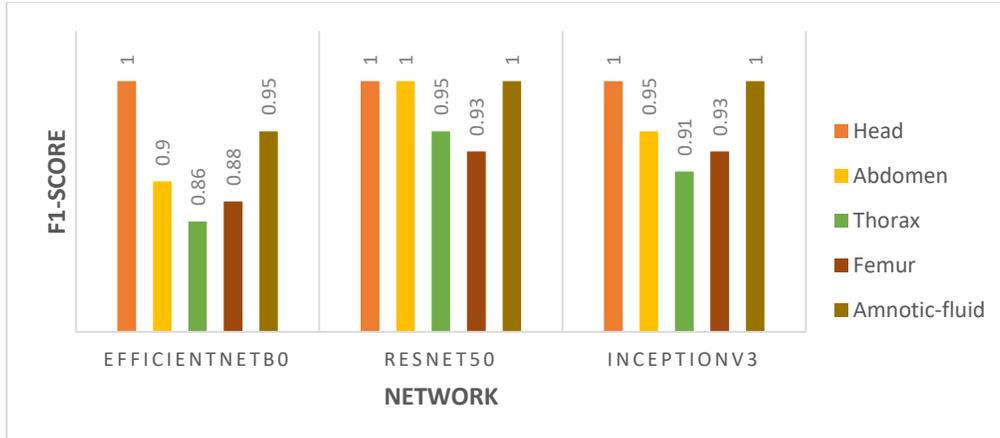


Figure III. 24 Histogramme de F1-Score avec Optimiseur SGD

**Remarque :**

À cette époque, le taux de classification d'EfficientNetB0 était la plus élevée (100 %) avec Adam et Nadam et la plus faible avec SGD, ResNet50 était la plus élevée (98 %) avec SGD mais faible avec Adam et Nadam et InceptionV3 est restée la même (96 %) avec tous les optimiseurs.

**Conclusion résultant :**

Avec des époques croissantes (12, 14, 15)

- *Adam* : EfficientNetB0 est passé de 98 % à 100 %, ResNet50 est passé de 91 % à 94 % puis 96 % respectivement et InceptionV3 est passé de 87 % à 98 % et a diminué à 96 %.
- *Nadam* : EfficientNetB0 est resté le même avec 98 % et a augmenté à 100 %, ResNet50 est resté le même tout au long avec 96 % et InceptionV3 est resté le même avec 98 % et a diminué à 96 %.
- *SGD* : EfficientNetB0 est passe de 87% à 89% puis à 91%, ResNet50 est reste le même à 96% et a augmenté à 98% et InceptionV3 est passe de 94% à 96%.

Même si tous les réseaux augmentent régulièrement avec SGD, nous avons choisi EfficientNetB0 avec l'optimiseur Adam qui nous a donné les résultats suivants :

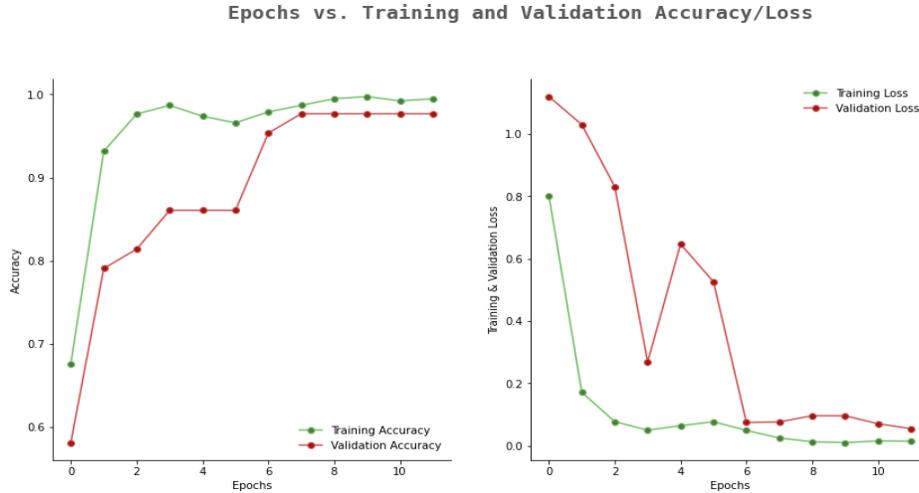


Figure III. 25 Graphe du taux de classification et la perte de l'apprentissage et la validation d'EfficientNetB0 avec Adam

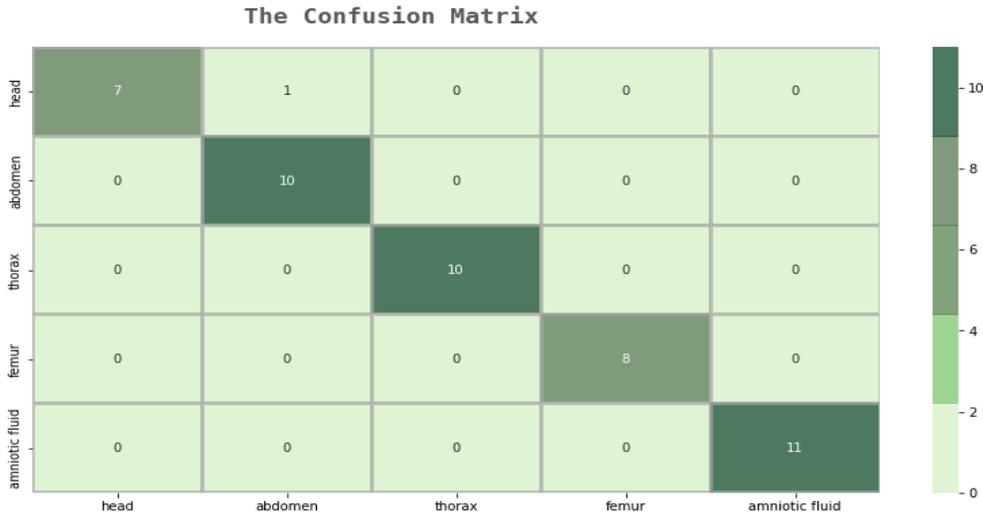


Figure III. 26 La matrice de confusion du modèle

### III.8 Augmentation des données

L'augmentation des données est un ensemble de techniques utilisées pour augmenter artificiellement la quantité de données en ajoutant des copies légèrement modifiées de données déjà existantes ou en créant de nouvelles données à partir de données existantes. Il agit comme un régularisateur et aide à réduire le sur-ajustement lors de l'apprentissage d'un modèle [79].

Nous utiliserons cette technique pour augmenter nos données en utilisant la fonction keras « ImageDataGenerator » avec les commandes qui font la rotation de l'image, décale l'image en largeur et en hauteur, change la luminosité, retourne l'image horizontalement et verticalement. Ce sont quelques exemples :



Figure III. 27 Exemples d'images augmentées

Ensuite, nous avons entraîné le modèle choisi « EfficientNetB0 avec Adam » en utilisant les images augmentées et nous avons eu les résultats suivants :

- Le taux de classification étant 94%
- Les résultats de F1-Score sont :

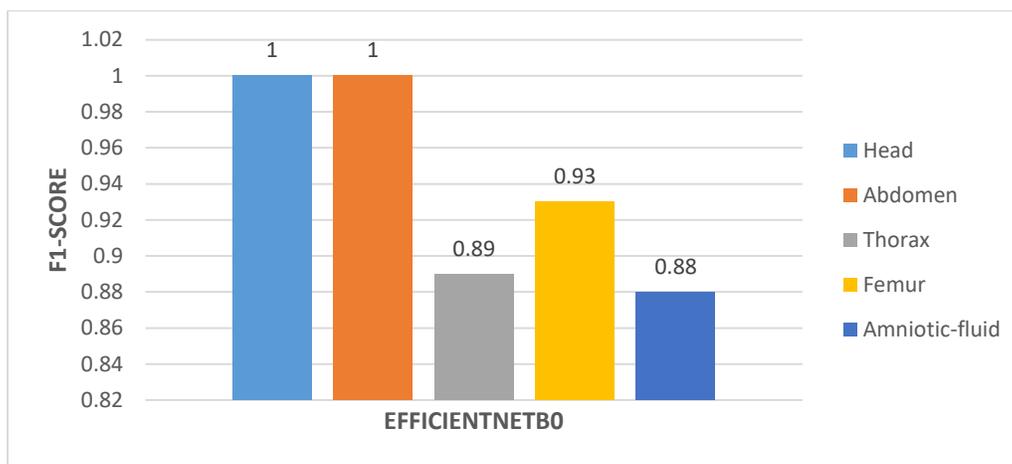


Figure III. 28 Histogramme de F1-Score d'EfficientNetB0 avec Adam après l'augmentation des images

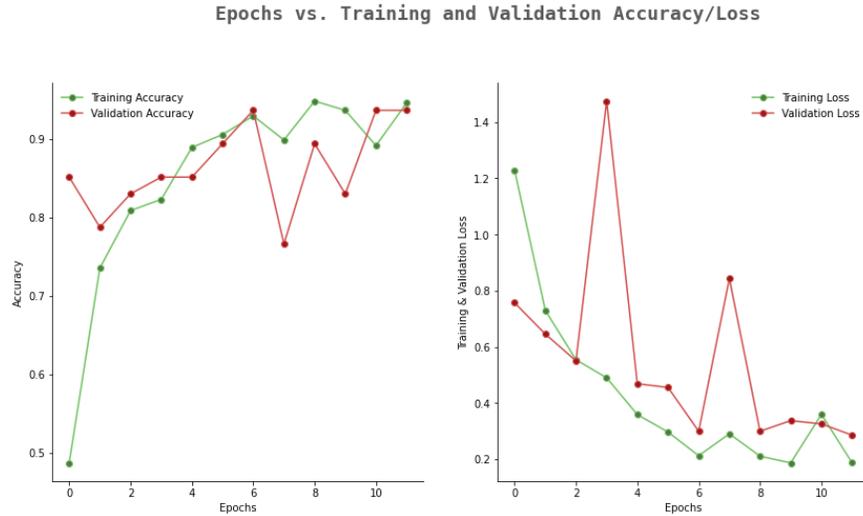


Figure III. 29 Graphe du taux de classification et la perte de l'apprentissage et la validation d'EfficientNetB0 après l'augmentation des images.

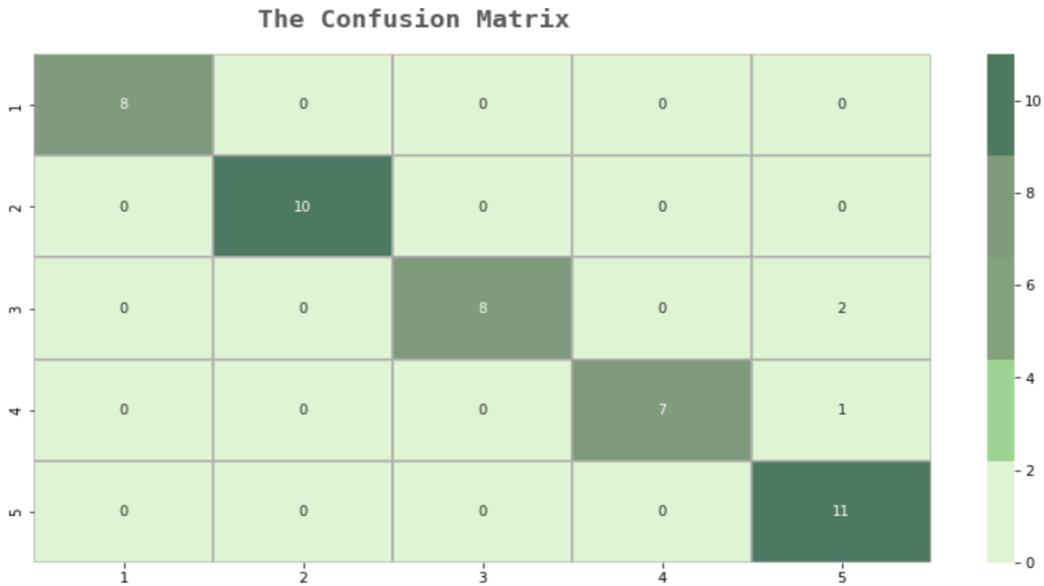


Figure III. 30 Matrice de confusion d'EfficientNetB0 après l'augmentation des images.

**Performance du modèle avant et après augmentation**

L'apprentissage initial du modèle a été effectué avec un nombre total de 235 images qui ont abouti à un taux de classification de 98%. Le nombre d'images a augmenté après augmentation, à 2063, ce qui a donné un taux de classification de 94%.

Dans un cas général, l'augmentation des données conduit à une augmentation du taux de classification, mais cela peut être affecté par l'apprentissage par transfert car un réglage fin

(fine-tuning) peut affecter la capacité du modèle. La diminution du taux de classification, même si le nombre d'images a augmenté, peut-être interprétée comme précise car on dit que le modèle réapprend les différentes images augmentées.

### **III.9 Conclusion**

Dans ce chapitre, nous avons utilisé le langage Python sur des plates-formes supportables pour classer nos images avec différents réseaux CNN en utilisant la méthode d'apprentissage par transfert et en modifiant le nombre d'époques, l'optimiseur et le nombre d'images qui font partie des paramètres qui déterminent les performances d'un modèle.

# Conclusion Générale

L'intérêt de ce travail porte sur la classification des coupes d'échographie fœtale pour le diagnostic et la prédiction des pathologies. L'objectif est d'étudier comment un système intelligent grâce à l'utilisation de réseaux de neurones convolutionnels peut classer automatiquement les images.

Le domaine médical fait partie des secteurs les plus critiques de la vie ! Nous saluons Ian Goodfellow pour sa grande contribution révolutionnaire au développement de CNN dans la classification d'images grâce à l'utilisation de l'apprentissage supervisé et non supervisé qui permet aux machines d'apprendre à l'aide de grands ensembles de données d'images et également de GAN. Le langage python a également contribué massivement à ce travail en raison de sa simplicité et de son efficacité dans l'exécution des codes. De plus, l'intégration de python et de TensorFlow augmente la vitesse de calcul et fournit une collection de flux de travail pour rendre les réseaux de neurones plus rapides et plus faciles à utiliser.

Ce projet est d'une grande importance car avec d'autres travaux comme la segmentation, c'est-à-dire l'identification soigneuse mais automatique des images échographiques du plan fœtal à partir de l'arrière-plan ou le filtrage des bruits pour rendre les images plus claires, nous rapproche de faire de la prédiction une réalité. Il sert également de tremplin pour obtenir des services médicaux appropriés et précis qui peuvent nécessiter moins de temps d'acquisition en raison des systèmes intelligents qui peuvent être développés à partir de ce travail, par exemple l'utilisation de Raspberry Pi. De plus, avec ce travail, nous pouvons contribuer à la précision des modèles entraînés sur des images générées à partir de GANs.

Parmi les limites de ce mémoire, citons : le manque de grandes quantités d'ensembles de données et leurs clartés. Ayant un petit ensemble de données entraîné sur un modèle CNN qui a été initialement entraîné sur un grand ensemble de données peut risquer de donner des prédictions peu fiables car le modèle peut ne pas avoir beaucoup de fonctionnalités à apprendre et pour éviter cela, nous avons augmenté le nombre d'images pour éviter le sur

ajustement pendant l'apprentissage ce qui finira par donner un taux de classification plus fiable.

Aussi l'exécution du code peut prendre du temps en fonction du temps d'exécution utilisé. La compatibilité des versions entre python et TensorFlow.

En conclusion, nous pouvons citer que :

- La santé du bébé et de la mère est importante et à haut risque de certaines infections et pathologies.
- L'échographie est une étape très importante durant la grossesse car il aide à suivre le développement du fœtus.
- La classification des images peut être effectuée soit par apprentissage supervisé, non supervisé ou par renforcement. Nous avons utilisé l'apprentissage non supervisé car il est idéal pour explorer des données brutes et inconnues, l'erreur humaine est minimisée et il est rapide à réaliser.
- L'architecture d'un modèle affecte la performance du taux de classification.

Nous envisageons nous envisageons de faire, comme perspectives :

- Ajouter d'autres pathologies dans notre système de classification.
- Augmenter diverses images médicales à l'aide de GAN.
- Mettre en place un système intelligent de classification.
- Essayez d'autres réseaux comme SVM (Support-Vector Machine) et RBF (Radial Basis Function network).

## Glossaires

Epoque : Signifie un passage complet de l'ensemble de données d'apprentissage à travers l'algorithme.

Fécondation : Initier la reproduction sexuelle, en transformant un ovule en œuf.

Nidation : Implantation de l'œuf des mammifères placentaires dans la muqueuse utérine.

Optimiseur : Implémentation particulière de l'algorithme de descente de gradient.

Semaine d'aménorrhée : La semaine d'aménorrhée débute au premier jour des dernières règles. L'aménorrhée correspond à l'absence des règles ou menstruations.

Sur-ajustement : Utiliser un modèle statistique qui a trop de paramètres par rapport à la taille de l'échantillon conduisant à un bon ajustement avec les données de l'échantillon mais un mauvais ajustement avec les nouvelles données.

# Références

- [1] Nagwa, «Fiche explicative de la leçon: Appareil reproducteur féminin,» 2022. [En ligne]. Available: <https://www.nagwa.com/fr/explainers/748160676139/>. [Accès le février 2022].
- [2] MadelnFutura Groupe , «Futura Santé,» Futura Sciences, 2001-2022. [En ligne]. Available: <https://www.futura-sciences.com/sante/defintions/biologie-uterus-3861/>. [Accès le 2022].
- [3] Cleveland Clinic, «Cleveland Clinic,» [En ligne]. Available: <https://my.clevelandclinic.org/health/articles/7247-fetal-development-stages-of-growth>. [Accès le 2022].
- [4] Institut national de santé publique Québec, «Institut national de santé publique Québec,» [En ligne]. Available: <https://www.inspq.qc.ca/mieux-vivre/grossesse/foetus/developpement-du-foetus>. [Accès le 2022].
- [5] Fondation Lucie et André Chagnon, «Fondation Lucie et André Chagnon,» [En ligne]. Available: <https://naitreetgrandir.com/fr/grossesse/>. [Accès le 2022].
- [6] Fondation Lucie et André Chagnon, «Fondation Lucie et André Chagnon,» [En ligne]. Available: <https://naitreetgrandir.com/fr/grossesse/trimestre2/grossesse-echographie/>. [Accès le 2022].
- [7] A. e. J. S. NG, "Resolution in ultrasound imaging," *Continuing Education in Anaesthesia, Critical Care & Pain*, vol. 11, no. 5, p. 190, 2013.
- [8] É. Y. S. Nguegang, «PREGNANCY ULTRASOUND,» 2007. [En ligne]. Available: [http://www.gfmer.ch/Medical\\_education\\_En/Cameroon\\_2007/pdf/Pregnancy\\_ultrasound\\_Sandjong\\_Yaounde\\_2007.pdf](http://www.gfmer.ch/Medical_education_En/Cameroon_2007/pdf/Pregnancy_ultrasound_Sandjong_Yaounde_2007.pdf). [Accès le 19 Mars 2022].
- [9] IndiaMART, «IndiaMART.com,» [En ligne]. Available: <https://m.indiamart.com/proddetail/ultrasound-transducer-13149558955.html>. [Accès le 2022].
- [10] Oriental Medical Equipment, «OME-Oriental Medical Equipment,» [En ligne]. Available: <https://orientalmedicalz.com/project/mindray-dc-60/>. [Accès le 2022].
- [11] N. Tole, "Ultrasonography," in *Basic physics of ultrasonographic imaging*, Geneva, World Health Organization Press by Harald Ostensen, 2005, p. 95.
- [12] M. BOYNARD, «4-Formation de l'image échographique,» Mai 2013. [En ligne]. Available: [http://naxos.biomedicale.univ-paris5.fr/diue/wp-content/uploads/2013/05/polyBasesPhysiques\\_04.pdf](http://naxos.biomedicale.univ-paris5.fr/diue/wp-content/uploads/2013/05/polyBasesPhysiques_04.pdf). [Accès le 23 Mars 2022].

- [13] Doctissimo, «Doctissimo,» [En ligne]. Available: [https://www.doctissimo.fr/html/grossesse/pendant/consultations/gr\\_4210\\_echographie.htm](https://www.doctissimo.fr/html/grossesse/pendant/consultations/gr_4210_echographie.htm). [Accès le 2022].
- [14] Passeport santé, «Oxygem- Charte de confidentialité- Passeport santé,» [En ligne]. Available: [https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=symptomes\\_grossesse\\_pm](https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=symptomes_grossesse_pm). [Accès le 2022].
- [15] L. Pam, C. Lyn, E. Tony and a. C. Trish, "Fetal size and dating: charts recommended for clinical obstetric practice," *ULTRASOUND*, vol. 17, no. 3, pp. 1-7.
- [16] A. J. S, «Obstetric ultrasound: where are we and where are we going?,» *Obstetric ultrasound*, vol. 1, n° 140, p. 57, 2021.
- [17] Passeport santé, «Oxygem- Charte de confidentialité- Passeport santé,» [En ligne]. Available: <https://www.passeportsante.net/famille/grossesse?doc=evolution-foetus>. [Accès le 2022].
- [18] Doctissimo, «Doctissimo (grossesse-pathologique),» [En ligne]. Available: <https://www.doctissimo.fr/html/grossesse/avant/envie-enfant/articles/15899-grossesse-pathologique.htm>. [Accès le 2022].
- [19] HAUTE AUTORITE DE SANTE, «Grossesses à risque : orientation des femmes enceinte entre les maternités en vue de l'accouchement,» Décembre 2009. [En ligne]. Available: [https://www.has-sante.fr/upload/docs/application/pdf/2010-04/grossesses\\_a\\_risque\\_-\\_recommandations.pdf](https://www.has-sante.fr/upload/docs/application/pdf/2010-04/grossesses_a_risque_-_recommandations.pdf). [Accès le 6 Mars 2022].
- [20] ASSISTANCE PUBLIQUE-HOPITAUX DE PARIS, [En ligne]. Available: <http://maternite-gynecologie.robertdebre.aphp.fr/pathologies-grossesse/>. [Accès le 2022].
- [21] Santé magazine, [En ligne]. Available: <https://www.santemagazine.fr/grossesse/grossesse-et-sante/grossesse-pathologique-quand-etre-enceinte-se-complice-897498>. [Accès le 2022].
- [22] D. K.-Z. M.A, «Placenta praevia,» [En ligne]. Available: <https://www.dr-karazaitrima.net/obstetrique/urgences-en-obstetrique/placenta-praevia/>. [Accès le 2022].
- [23] C. N. d. G. e. O. F. (CNGOF), «Item 18 : Grossesses Extra-Utérine (GEU),» Université Médicale Virtuelle Francophone, 2015-2016. [En ligne]. Available: <http://campus.cerimes.fr/gynecologie-et-obstetrique/enseignement/item18/site/html/cours.pdf>. [Accès le 7 Avril 2022].
- [24] Children's Hospital of Philadelphia, Children's Hospital of Philadelphia, [En ligne]. Available: <https://www.chop.edu/conditions-diseases/premature-rupture-membranes-prompreterm-premature-rupture-membranes-pprom#>. [Accès le 2022].

- [25] C. N. d. G. e. O. F. (CNGOF), «Item 21 : Retard de Croissance Intra-Utérin (RCIU),» Université Médicale Virtuelle Francophone, 2015-2016. [En ligne]. Available: <http://campus.cerimes.fr/gynecologie-et-obstetrique/enseignement/item18/site/html/cours.pdf>. [Accès le 26 Fevrier 2022].
- [26] D. PELEG, C. M. KENNEDY et a. S. K. HUNTER, «Identification and Management,» *Intrauterine Growth Restriction*, vol. 58, n° %12, pp. 453-460, 1998.
- [27] C. L. Walker, E. O. Ohuma et e. al, «Femur-sparing pattern of abnormal fetal growth in pregnant women from New York City after maternal Zika virus infection,» *American Journal of Obstetrics and Gynecology*, vol. 219, n° %12, p. 187.
- [28] M. E. Ayoubi, *Le retard de croissance intra-utérin et la grande prématurité : impact sur la mortalité et les morbidités à court et à moyen terme*, Paris, 2015.
- [29] The Nemours Foundation, «kidshealth.org,» The Nemours Foundation, [En ligne]. Available: <https://kidshealth.org/en/parents/iugr.html>. [Accès le 2022].
- [30] Mayo Clinic, «Healthy Lifestyle-Pregnancy week by week,» Mayo Foundation for Medical Education and Research (MFMER), [En ligne]. Available: <https://images.app.goo.gl/QjG3rqvPPxP6ipQj6>. [Accès le 2022].
- [31] viatech.com, «history-of-artificial-intelligence,» VIA TECHNOLOGIES, INC., [En ligne]. Available: <https://www.viatech.com/en/2018/05/history-of-artificial-intelligence/>.
- [32] G. Bochra et S. Safia, «Les réseaux de neurone convolutionel Mémoire Master : (CNN) pour la classification des images associées aux places de stationnement d'un parc de véhicule,» Université Djilali Bounaama Khemis Miliana, Khemis Miliana, 2018/2019.
- [33] Analytics India Magazine, Analytics India Magazine Pvt Ltd 2022, [En ligne]. Available: <https://analyticsindiamag.com/the-history-of-machine-learning-algorithms/>. [Accès le 2022].
- [34] M. AMMAR, «Chapitre No1, Modélisation et Simulation des systèmes physiologiques,» chez *Deep Learning pour la classification des images*, Boumerdès-Université de Boumerdès, 2021-2022.
- [35] avatpoint.com, «unsupervised-machine-learning,» JavaTpoint, [En ligne]. Available: <https://www.javatpoint.com/unsupervised-machine-learning>. [Accès le 2022].
- [36] S. Bhatt, «reinforcement-learning-101,» Towards Data Science, 19 Mars 2018. [En ligne]. Available: <https://towardsdatascience.com/reinforcement-learning-101-e24b50e1d292>. [Accès le 2022].
- [37] «Intelligence artificiel,» CONSEIL DE L'EUROPE, [En ligne]. Available: <https://www.coe.int/fr/web/artificial-intelligence/glossary>. [Accès le 2022].

- [38] Y. Djeriri, «Les Réseaux de Neurones Artificiels,» Septembre 2017. [En ligne]. Available: <https://www.researchgate.net/publication/319939107>. [Accès le 18 Avril 2022].
- [39] M. AMMAR, «Réseaux de Neurones,» chez *Modélisation et Simulation des systèmes physiologiques*, Boumerdès, Université de Boumerdès, 2021/2022.
- [40] C. Touzet, «LES RESEAUX DE NEURONES ARTIFICIELS, INTRODUCTION AU CONNEXIONNISME : COURS, EXERCICES ET TRAVAUX PRATIQUES,» chez *LES RESEAUX DE NEURONES ARTIFICIELS, INTRODUCTION AU CONNEXIONNISME : COURS, EXERCICES ET TRAVAUX PRATIQUES*, Collection de l'EERIE par N. Giambiasi, 1992.
- [41] C. L. Jeremy et B., «Segmentation d'images cérébrales,» *Etat de l'art*, p. p.13, Janvier 2007.
- [42] M. AMMAR, «Les réseaux de Neurones,» chez *Modélisation et Simulation des systèmes physiologiques*, Boumerdès, Université de Boumerdès, 2019.
- [43] Simplilearn Solutions, «ai-vs-machine-learning-vs-deep-learning,» Simplilearn Solutions, [En ligne]. Available: <https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/ai-vs-machine-learning-vs-deep-learning>. [Accès le 2022].
- [44] A. Insight, «the-history-evolution-and-growth-of-deep-learning,» Analytics Insight, [En ligne]. Available: <https://www.analyticsinsight.net/the-history-evolution-and-growth-of-deep-learning/>.
- [45] Guru99, «backpropogation-neural-network,» [En ligne]. Available: <https://www.guru99.com/backpropogation-neural-network.html>. [Accès le 2022].
- [46] Towards AI Inc., «towardsai.net,» Towards AI Inc., [En ligne]. Available: <https://towardsai.net/p/machine-learning/main-types-of-neural-networks-and-its-applications-tutorial-734480d7ec8e>. [Accès le 2022].
- [47] Iterators Sp.z.o.o, «www.iteratorshq.com,» Iterators Sp.z.o.o, [En ligne]. Available: <https://www.iteratorshq.com/blog/machine-learning-vs-deep-learning-the-ultimate-comparison/>. [Accès le 2022].
- [48] A.Khan, A.Sohail, U. Zahoora et Q. A. Saeed, «A survey of the recent architectures of deep convolutional neural networks,» *Artif Intell Rev* 53, pp. 5455-5516, 2020.
- [49] B. Timea et B.Nebojsa, «Convolutional Neural Network Layers and Architectures,» chez *International Scientific Conference On Information Technology and Data Related Research*, Singindunum University, Serbia, 2019.
- [50] M. Ameer et K. Akram, Mémoire Master : Classification des images utilisant les réseaux de neurones de convolution, Bordj Bou Arreridj: Université de Mohamed El-Bachir El-Ibrahimi, 2020/2021.

- [51] «[www.datakeen.co](https://www.datakeen.co/),» DATAKEEN, [En ligne]. Available: <https://www.datakeen.co/3-deep-learning-architectures-explained-in-human-language/>.
- [52] M. AMMAR, « Traitement d'images,» chez *Chapitre I Prétraitements, Traitement de l'image médicale*, Boumerdès, Université de Boumerdès, 2021.
- [53] J. KIM, «[gaussian37.github.io](https://gaussian37.github.io/),» [En ligne]. Available: <https://gaussian37.github.io/dl-concept-cnn/>. [Accès le 2022].
- [54] R. Waseem et W. Zenghui, «Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review,» *Neural Computation*, vol. 29, n° %19, pp. 1-98.
- [55] K. Ibrahim et C. Mauro, «Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image Classification. A Review,» *Applied Sciences*, vol. 10, n° %16, pp. 1-24.
- [56] Machine Learning Mastery, «[machinelearningmastery.com](https://machinelearningmastery.com/),» Machine Learning Mastery, [En ligne]. Available: <https://machinelearningmastery.com/softmax-activation-function-with-python/>. [Accès le 2022].
- [57] J. A. Ameh, M. A. et e. al, «Improved multi-classification of breast cancer histopathological images using handcrafted features and deep neural networks (dense layer),» *Intelligent Systems with Applications*, vol. 14, n° %1200066.
- [58] «[analyticsindiamag.com](https://analyticsindiamag.com/),» Analytics India Magazine Pvt Ltd, [En ligne]. Available: <https://analyticsindiamag.com/loss-functions-in-deep-learning-an-overview/>. [Accès le 2022].
- [59] A. T. Habib, A. Alam, K. M. Numan et K. Jawad, «A Multimodal Memes Classification: A Survey and Open Research Issues,» *SIAT: A Distributed Video Analytics Cloud Platform for Intelligent Video Analytics*, vol. 1, n° %108395.
- [60] Analytics Vidhya, «[www.analyticsvidhya.com](https://www.analyticsvidhya.com/),» [En ligne]. Available: <https://www.analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/>. [Accès le 2022].
- [61] A. H. Reynolds, «[anhreynolds.com](https://anhreynolds.com/),» [En ligne]. Available: <https://anhreynolds.com/blogs/alexnet.html>. [Accès le 2022].
- [62] Viso.ai, «[viso.ai](https://viso.ai/),» [En ligne]. Available: <https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks/>.
- [63] «[towardsdatascience.com](https://towardsdatascience.com/),» Towards Data Science, [En ligne]. Available: <https://towardsdatascience.com/a-simple-guide-to-the-versions-of-the-inception-network-7fc52b863202>.
- [64] R. F. a. W. Brian, «Comparing pattern sensitivity of a convolutional neural network with an ideal observer and support vector machine,» 2019.

- [65] Cornell University, «arxiv.org,» arXiv (Cornell University), [En ligne]. Available: <https://arxiv.org/abs/1905.11946>. [Accès le 2022].
- [66] M. F. J. Perez et A. A. Sarraga, «Empirical Analysis of a Fine-Tuned Deep Convolutional Model in Classifying and Detecting Malaria Parasites from Blood Smears,» *KSII Transactions On Internet and Information Systems*, vol. 15, n° 11, pp. 147-165.
- [67] W. Koehrsen, «towardsdatascience.com,» Towards Data Science, 26 Novembre 2018. [En ligne]. Available: Towards Data Science, <https://towardsdatascience.com/transfer-learning-with-convolutional-neural-networks-in-pytorch-dd09190245ce>. [Accès le 22 Mai 2022].
- [68] E. Houby, «Using transfer learning for diabetic retinopathy stage classification,» *Applied Computing and Informatics*, 2021.
- [69] A. Sweigart, AUTOMATE THE BORING STUFF WITH PYTHON, San Francisco: no starch press, 2015.
- [70] Wikiversity, «en.wikiversity.org,» [En ligne]. Available: <https://en.wikiversity.org/wiki/Python>. [Accès le 2022].
- [71] B. L, «www.lebigdata.fr,» Groupe Publithings, 19 Octobre 2018. [En ligne]. Available: <https://www.lebigdata.fr/tensorflow-definition-tout-savoir>. [Accès le 2022].
- [72] TensorFlow, «tensorflow.org,» TensorFlow, [En ligne]. Available: <https://tensorflow.org>. [Accès le 2022].
- [73] Keras, «keras.io,» Keras, [En ligne]. Available: <https://keras.io/>. [Accès le 2022].
- [74] Google, «research.google.com,» Google, [En ligne]. Available: <https://research.google.com/colaboratory/faq.html>. [Accès le 2022].
- [75] «colab.research.google.com,» Google Colab, [En ligne]. Available: [https://colab.research.google.com/drive/1LrKRV1zBcA18hc-9EK\\_IRLI8N28Djv9J?usp=sharing](https://colab.research.google.com/drive/1LrKRV1zBcA18hc-9EK_IRLI8N28Djv9J?usp=sharing). [Accès le 2022].
- [76] C. C. e. C. Tremblay, «kobia.fr,» Kobia, 16 Novembre 2021. [En ligne]. Available: <https://kobia.fr/classification-metrics-matrice-de-confusion>. [Accès le 2022].
- [77] Google Developers, «developers.google.com,» Machine Learning Crash Course, [En ligne]. Available: <https://developers.google.com/machine-learning/crash-course/classification/>. [Accès le 2022].
- [78] F-Score, «deepai.org,» Deep AI , [En ligne]. Available: <https://deepai.org/machine-learning-glossary-and-terms/f-score>. [Accès le 2022].
- [79] A. Takimoglu, «research.aimultiple.com,» AI Multiple, 30 Avril 2021. [En ligne]. Available: <https://research.aimultiple.com/data-augmentation/>. [Accès le 2022].

[80] C. L. Jeremy et B., «Segmentation d'images cérébrales,» *Etat de l'art*, n° 16306, p. p.13, January 2007.