

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET
POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche
Scientifique

جامعة أبي بكر بلقايد – تلمسان –
Université Aboubakr Belkaïd – Tlemcen –
Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Génie biomédical

Spécialité : Imagerie Médicale

Par : Mekhaznia Soumia

Sujet

**La détection des pathologies gastriques par les méthodes
d'apprentissage profond**

Soutenu publiquement, le 11/06/2023, devant le jury composé de :

M/ Boukli Hacene Ismail	MCA	Université de Tlemcen	Président
Mme/ Feroui Amel	MCA	Université de Tlemcen	Examinatrice
M/ Messadi Mahammed	Prof	Université de Tlemcen	Encadrant
Mlle/ Elaouaber Zineb Aziza	Donctorante	Université de Tlemcen	Co-Encadrante

REMERCIEMENT

Tout d'abord, je tiens à remercier **ALLAH** , De m'avoir donné la santé, la volonté et la patience pour élaborer ce travail.

Je souhaite exprimer ma profonde reconnaissance envers mon encadreur **Monsieur MESSADI MAHAMED** professeur à l'université de Tlemcen, pour avoir accepté de me guider et de superviser mon projet de fin d'étude. Sa patience et ses précieux conseils ont été d'une valeur inestimable tout au long de cette période.

Je tiens à exprimer ma profonde reconnaissance envers **Mlle ELAOUABER ZINEB AZIZA** pour son aide précieuse. Sa compétence, son expertise et sa volonté d'aider ont été une source d'inspiration pour moi. Sa générosité et son dévouement ont eu un impact significatif sur mon parcours.

Je tiens à remercier **Monsieur BOUKLI HACENE ISMAIL** maître de conférence à l'université de Tlemcen, qui a bien voulu me faire l'honneur de présider mon projet de fin d'étude.

J'exprime également notre gratitude envers **Madame FEROUJ AMEL** maître de conférence à l'université de Tlemcen pour l'intérêt qu'elle a témoigné envers ce travail en acceptant de l'examiner.

Je tiens également à exprimer ma gratitude envers toute l'équipe pédagogique de la faculté de technologie de Tlemcen, qui a été responsable de ma formation tout au long de mon parcours universitaire. Leur engagement et leur dévouement ont contribué à garantir une expérience éducative de qualité.

Dédicace

A mes chers parents

Depuis ma naissance jusqu'à aujourd'hui, vous avez été constamment présents à mes côtés, offrant un soutien infaillible. Ce modeste travail est le fruit des efforts et des sacrifices que vous avez consentis tout au long de mon éducation et de ma formation. Vos encouragements ont été une source inestimable de motivation pour moi." وقل ربّي ارحمهما كما ربياني
صغیرا

A mes frères Mohamed et Emir et ma sœur Imene

Pour les précieux souvenirs que nous avons partagés, les moments de rire, les confidences partagées et la camaraderie que nous avons construite. Votre présence dans ma vie est d'une valeur inestimable et je suis honorée d'être liée à vous à travers nos liens familiaux et les expériences que nous avons vécues ensemble.

A mes meilleures amies

Mes copines et surtout Younsi Imene, Tu as été capable de croire en mes rêves et de m'encourager à poursuivre mes objectifs. Ta confiance en moi a été une force motrice pour mon développement personnel. Je ressens une profonde gratitude de t'avoir à mes côtés tout au long de mon parcours.

A mes collègues

Mes camarades de classe qui ont été présents depuis le début de mon parcours, et particulièrement envers mon petit groupe pendant ces deux années de Master. Je suis reconnaissante d'avoir eu l'opportunité de travailler avec des individus aussi talentueux et inspirants. Votre énergie positive, votre enthousiasme et votre capacité à relever les défis avec confiance ont été une source d'inspiration constante pour moi.

Et à toute personne par de petites actions ou de simples gestes de gentillesse, illuminent notre chemin.

Résumé

Plusieurs pathologies gastriques touchent le système digestif à cause de divers facteurs. Elles peuvent être détectées à l'aide de multiples examens cliniques. L'endoscopie est l'une des meilleures méthodes d'exploration de tube gastro-intestinal (GI). Le problème majeur de cette technique est la qualité médiocre d'image à cause du flou, la faible luminosité, la viscosité et les artefacts. Ce problème peut perturber le diagnostic médical. Le traitement d'image est donc nécessaire pour faciliter le diagnostic et la prise en charge des maladies GI.

Récemment, l'Intelligence Artificielle (IA) est devenue un outil essentiel pour l'interprétation des images médicales. Grâce aux algorithmes de Deep Learning, il peut extraire des paramètres et classifier les images avec une grande précision, même lorsque les sont de qualité dégradée et les paramètres ne sont pas clairement définis.

Dans ce travail, nous présenterons une méthode automatique de détection des anomalies gastriques en utilisant différentes approches basées sur l'apprentissage profond. Nous avons réalisé une étude comparative entre trois modèles pré-entraînés les plus populaires qui sont : AlexNet, VGG16 et VGG19 pour classifier les cas pathologiques. Ensuite nous étudions l'importance de l'étape d'augmentation de base de données dans l'amélioration des performances du système. Enfin, nous effectuons une étude comparative entre les différentes conditions pour faire la classification. Pour entraîner et évaluer nos méthodes, nous avons sélectionné les classes pathologiques de la base de données Kvasir.

Ainsi, les résultats obtenus sont impressionnants surpassant les travaux existant. Le modèle pré-entraîné VGG19 avec l'augmentation des données a donné le meilleur taux de classification avec une valeur de 99,9%.

Mots clés : maladies digestives, système gastro-intestinal, imagerie endoscopique, deep learning, transfert learning.

Abstract

Gastric pathologies affect the digestive system for a variety of reasons. Endoscopy is one of the best methods for exploring the gastrointestinal (GI) tract. The major problem with this technique is image quality, due to blurring, low brightness and artifacts. This problem can

impair medical diagnosis. Image processing is necessary in this case to facilitate medical decision-making.

Recently, Artificial Intelligence (AI) has become an essential tool for medical image interpretation. Thanks to Deep Learning algorithms, it can extract parameters and classify them, even when the parameters are not clearly defined.

In this work, we present a method for processing medical images to detect gastric anomalies. We use Deep Learning-based approaches. We select pathological classes from the Kvasir database to achieve our goal. We perform a comparative study between the original and pre-trained models AlexNet, VGG16 and VGG19 to classify pathological cases. We then study the importance of the database augmentation step in improving system performance. Finally, we carry out a comparative study between different classification conditions. The maximum classification rate exceeds 99.9% in the case of the VGG19 pre-trained model when the database is augmented.

Keywords : gastric pathologies, the gastrointestinal (GI) tract 1, deep learning, transfert learning

Table de matières

Remerciements.....	II
Dédicace.....	III
Résumé.....	IV
Abstarct.....	IV
Table de Matière.....	VI
LISTE DES FIGURES.....	XI
LISTE DES TABLEAUX	XIV
LISTES DES ABREVIATION.....	XV
Introduction générale	1
Chapitre I : Aspect médical	
I.1 Introduction.....	4
I.2 Le système digestif.....	4
I.2.1 La cavité buccale et son contenu.....	5
I.2.1.1 Cavité buccale	5
I.2.1.2 Les glandes salivaires	5
I.2.2. Le tube digestif.....	6
I.2.2.1 L'œsophage	6
I.2.2.2 L'estomac.....	6
I.2.2.3 L'intestin grêle	7
I.2.2.4 Le gros intestin	8

I.2.2.5 Le rectum	9
I.2.3 Les annexes	9
I.2.3.1 Le foie	9
I.2.3.2 Le pancréas	10
I.3 Les pathologies gastriques	10
I.3.1 Reflux gastro-œsophagien (RGO)	10
I.3.2 L'œsophagite	11
I.3.3 Cancer de l'œsophage	12
I.3.4 L'œsophage de BARRETT	12
I.3.5 Le cancer de l'estomac	12
I.3.6 Les polypes	12
I.3.7 Le cancer du côlon	14
I.3.8 La colite ulcéreuse	14
I.4 Les moyens d'exploration du système digestif	14
I.4.1 L'endoscopie	15
I.4.2 Abdomen sans préparation ASP	16
I.4.3 Transit du grêle	16
I.4.4 Lavement baryté	16
I.4.5 Echographie	17
I.4.6 Tomodensitométrie (TDM)	17
I.4.7 Colonographie par TDM	18
I.4.8 Imagerie par Résonance Magnétique (IRM)	18
I.4.9 Laparoscopie (œlioscopie)	19

Conclusion	19
CHAPITRE II. Etat de l'art et principe de deep learning	
II.1. Introduction	21
II.2. L'état de l'art	21
II.3. L'intelligence artificielle (IA).....	23
II.4 L'apprentissage automatique	23
II.4.1 L'apprentissage supervisé.....	23
II.4.2 L'apprentissage non supervisé.....	24
II.4.3 L'apprentissage semi-supervisé	24
II.5 Le réseaux de neurones artificiels.....	24
II.5.1 Le perceptron.....	24
II.5.2 Les réseaux de neurones artificiels multicouches (MLP).....	25
II.5.3 L'algorithme de la rétropropagation	26
II.5.4 La fonction d'activation	26
II.6 Principe du deep learning	27
II.6.1 Définition.....	27
II.6.2 Réseaux de neurones convolutifs (CNN)	27
II.6.3. L'architecture d'algorithme	28
II.6.4 Les couches du CNN.....	29
II.6.4.1 La couche de convolution.....	29
II.6.4.2 La couche de correction.....	29
II.6.4.3 La couche de pooling.....	30
II.6.4.4 La couche entièrement connectée (fully connected	30

II.6.4.5 Les algorithmes d'optimisation.....	31
II.7. Transfert learning.....	31
II.8 Les modèles de deep learning les plus populaires.....	32
II.8.1 AlexNet.....	32
II.8.2 VGGNet.....	33
II.9 L'évaluation du modèle.....	34
II.9.1 La matrice de confusion.....	34
II.9.2 Taux de classification (accuracy.....	34
II.9.3 Précision.....	35
II.9.4 Sensibilité.....	35
II.9.5 La spécificité.....	35
Conclusion.....	35

CHAPITRE III : RESULTATS ET DISCUSSION

I. Introduction.....	37
III.2 Matériels et méthodes.....	37
III.2.1 Matériel utilisés.....	37
III.2.1.1 Base de données.....	37
III.2.1.2 Software et hardware.....	38
III.2.2 Les méthodes proposées.....	38
III.2.2.1 Prétraitement des données.....	38
III.2.2.2 l'augmentation des données.....	39
III.2.2.3 Classification des pathologies Gastro-intestinales.....	40
III.2.2.3.1 AlexNet.....	40
III.2.2.3.2 VGG16.....	41

III.2.2.3.3 VGG19	41
III.2.2.4 Partie expérimentale.....	41
III.2.2.4.1 Les paramètres d'apprentissage.....	41
III.2.2.4.2 Les expérimentations	42
III.2.2.4.2.1 Le modèle non pré-entraîné.....	42
III.2.2.4.2.1.1 Progression d'entraînement du modèle non pré entraîné	42
III.2.2.4.2.1.2 L'interprétation des résultats de validation	43
III.2.2.4.2.2 Les réseaux pré entraînés.....	44
III.2.2.4.2.2.1 Progression d'entraînement	45
III.2.2.4.2.1.2 L'interprétation des résultats de validation	46
III.2.2.4.2.3 Les réseaux pré entraînés dans le cas de la base sans augmentation	49
III.2.2.4.2.3.1 Progression d'entraînement	50
III.2.2.4.2.3.2 L'interprétation des résultats de validation	52
III.2.2.5 Discussion	54
III.2.2.5 .1 Comparaison entre les trois méthodes.....	55
III.2.2.5 .2Comparaison avec l'état de l'art	55
III.3 Interface graphique	56
Conclusion	58

La liste des figures

Chapitre I : Aspect médical

Figure I.1 : Le système digestif	4
Figure I.2 : La cavité buccale	5
Figure I.3 : les glandes et les canaux salivaires.....	5
Figure I.4 : Anatomie de l'estomac	7
Figure I.5 : Villosité intestinale	8
Figure I.6 : Le gros intestin.....	9
Figure I.7 : anatomie du foie et de la vésicule biliaire.....	9
Figure I.8 :RGO reflux gastrique.....	10
Figure I.9 : Une oesophgite diagnostquée par endoscopie.....	11
Figure I.10 : Image endoscopique d'un polype.....	13
Figure I.11 : Polypectomie	13
Figure I.12 : opérations faites sur les polypes.....	13
Figure I.13 : La colite ulcéreuse	14
Figure I.14 : L'endoscopie flexible	15
Figure I.15 : L'endoscope rigide	16
Figure I.16 : Lavement baryté.....	17
Figure I.17 : Scanner abdominopelvien.....	17
Figure I.18 : Colonographie	18
Figure I.19 : Image IRM abdominale	19
Figure I.20 : Laparoscopie	19

CHAPITRE II : Etat de l'art et principe d'Apprentissage profond

Figure II.1: Neurone biologique et neurone artificiel.....	24
Figure II.2 : Architecture du perceptron.....	25
Figure II.3 : Structure du modèle de réseau de neurone artificiel	25
Figure II.4 : Les phases dans l'utilisation de réseau de neurones artificiels	26

Figure II.5 : Illustration graphique du processus de la rétropropagation.....	26
Figure II.6 : La relation entre AI, l'apprentissage automatique et le deep learning.....	27
Figure II.7 : Architecture d'un algorithme de CNN.....	28
Figure II.8 : Filtre de convolution.....	29
Figure II.9 : Principe de fonctionnement de ReLU.....	30
Figure II.10 : Exemple de pooling avec les différentes stratégies (maximum, moyen). La taille des fenêtres ainsi que le pas utilisé dans cet exemple sont de 2x2.....	30
Figure II.11 : Couche Fully Connected.....	31
Figure II.12 : Différence entre apprentissage normal et apprentissage par transfert.....	32
Figure II.13 : Architecture Alexnet.....	32
Figure II.14 : Architecture VGG16.....	33
Figure II.15 : Architecture VGG19.....	33
Figure II.16 : Matrice de confusion.....	34
 CHAPITRE III	
Figure III.1 : Exemple de chaque classe de la base de données KVASIR.....	38
Figure III.2: Suppression des carrés en vert.....	39
Figure III.3 : Augmentation des données.....	40
Figure III.4: Développement de précision et la perte dans le modèle AlexNet non pré entraîné.....	43
Figure III.5 : la matrice de confusion AlexNet non pré entraîné.....	43
Figure III.6 : Développement de précision et la perte dans le modèle AlexNet pré entraîné ..	45
Figure III.7 : Développement de précision et la perte dans le modèle VGG16 pré entraîné ...	46
Figure III.8 : Développement de précision et la perte dans le modèle VGG19 pré entraîné ...	46
Figure III.9: la matrice de confusion AlexNet pré entraîné.....	47
Figure III.10: la matrice de confusion VGG16 pré entraîné.....	47
Figure III.11: la matrice de confusion VGG19 pré entraîné.....	48

Figure III.12 : Développement de précision et la perte dans le modèle AlexNet pré entraîné (base sans augmentation)	50
Figure III.13 : Développement de précision et la perte dans le modèle VGG16 pré entraîné (base sans augmentation)	51
Figure III.14 : Développement de précision et la perte dans le modèle VGG19 pré entraîné (base sans augmentation)	51
Figure III.15 : La matrice de confusion du modèle AlexNet dans le cas de la base sans augmentation.....	52
Figure III.16: La matrice de confusion du modèle VGG16 dans le cas de la base sans augmentation.....	52
Figure III.17 : La matrice de confusion du modèle VGG19 dans le cas de la base sans augmentation.....	53
Figure III.18 : interface graphique.....	57
Figure III.19 : detection de l'oeosophagite.....	57
Figure III.20 detection des polypes	58
Figure III.21 detection de la colite ulcéreuse	58

Liste des tableaux

Tableau III.1 : les paramètres d'apprentissage	42
Tableau III.2 : métriques des classes avec le modèle AlexNet non pré entraîné	44
Tableau III.3 : métriques des classes de la base augmentée et les modèles pré entraînés	48
Tableau III.4 : métriques moyennes dans chaque modèle	49
Tableau III.5 : métriques des classes de la base sans augmentation et les modèles pré	53
Tableau III.6 : métriques moyennes des classes de la base augmentée et pré entraînée	54
Tableau III.7 : table comparative entre les méthodes de la littérature et nos méthodes	55

Liste des abréviations

AI : Artificial Intelligence

DL : Deep Learning

GI : Gastro_Intestinale

RGO : Reflux Rastro-œsophagien

ASP : Abdomen Sans Préparation

TDM: Tomodensitométrie

IRM: Imagerie par Résonance Magnétique

MFE : Multi-scale Feature Extraction

FCN: Fully Convontional Network

DCA: Detail Capture Attention

SLIC: Simple Linear Iterative Clustering

FRFCM: Rast and Fobust Fuzzy C Means

CNN: Convontional Neural Network

LSTM: Long Short Term Memory

ReLU: Rectified Linear Unit

DSF : Dense Sampling Fusion

VGG: Visual Geometry Group

FC : Fully Connected

CONV: convolution

Introduction générale

Le système digestif est le système responsable de la digestion et l'absorption des aliments chez l'être humain. Il est complexe et englobe un ensemble d'organe dont chacun joue un rôle spécifique. Le processus de digestion commence dès la bouche et se poursuit tout au long du tractus gastro-intestinal. Et à l'aide des organes annexes, les aliments sont fragmentés en petites molécules connues sous le nom des nutriments. Le système digestif est affecté par des pathologies causées par différents facteurs (génétiques, héréditaires, inflammatoire ...) ou par le mode de vie. Ces maladies sont nombreuses et parfois dangereuses et présentent des risques sur la vie du patient. L'imagerie médicale offre des techniques variantes afin de diagnostiquer les différentes pathologies de système digestif.

L'endoscopie digestive est une technique avantageuse en gastrologie, elle permet de visualiser l'intérieur de tube digestif en temps réel et effectuer des interventions chirurgicales pour faire des prélèvements de tissus ou traiter une pathologie. Les médecins utilisent la fibroscopie pour l'exploration de la partie haute de tube digestif, et la coloscopie pour l'exploration de la partie basse.

La qualité de l'image endoscopique peut varier en fonction de nombreux facteurs tels que la résolution de l'appareil, l'éclairage, la stabilité de l'image, la présence de distorsion ou de bruit. Une mauvaise qualité d'image peut rendre difficile l'identification précise des structures anatomiques ou des lésions.

Le traitement d'image représente l'ensemble de techniques et d'algorithmes visant à améliorer, restaurer, analyser, segmenter et interpréter les images afin d'extraire des informations utiles et donner la décision finale. En médecine, les outils de traitement d'image permettent la détection automatique des pathologies et favorisent la création des systèmes aide au diagnostic médical.

D'un autre côté, de nos jours, l'intelligence artificielle (IA) est devenue omniprésente dans notre société notamment en médecine. Elle est capable d'effectuer des tâches qui étaient auparavant réservées aux êtres humains. Le deep learning est une branche de l'intelligence artificielle qui a connu des avancées significatives ces dernières années. Il utilise des réseaux de neurones convolutifs (CNN) pour analyser et interpréter de grandes quantités de données. Grace à ses architectures et modèles, de nouvelles perspectives en traitement des images médicales notamment en gastrologie ont été ouvert. Ces architectures sont capables

d'interpréter les images et des vidéos endoscopiques et détecter les anomalies d'une manière automatique.

Plusieurs travaux dans la littérature ont été présentés pour la détection des pathologies gastriques. Les chercheurs dans ce domaine sont divisés en deux groupes. Le premier groupe a utilisé les outils classiques de traitement d'images comme les filtres linéaires et non linéaires. Leur but est de segmenter les anomalies puis les classifier. Le deuxième groupe a concentré sur l'exploitation de l'IA ce qui permet la segmentation et/ou la classification automatiques des maladies.

Dans le cadre de ce mémoire de fin d'étude, nous allons employer trois architectures de deep learning pour la classification des pathologies gastriques à partir des images endoscopiques. Ces modèles seront entraînés et testés sur la base de données publique kavasir.

Le reste de ce travail est organisé comme suit :

- ✓ Dans le premier chapitre, nous présenterons le système digestif, le rôle de chaque organe dans la digestion. Les différentes pathologies gastriques les plus connues seront ensuite citées. Par la suite nous allons parler sur les techniques d'imagerie utilisées pour l'exploration de ce système en concentrant sur l'endoscopie.
- ✓ Dans le deuxième chapitre, nous allons définir l'IA et ses branches ainsi que le deep learning et ses modèles qui seront utilisés pour atteindre notre but. Dans ce chapitre nous allons définir les différentes couches d'un modèle de réseaux de neurones convolutionnels (CNN) afin de comprendre le but et l'importance de chacune.
- ✓ Dans le dernier chapitre nous présenterons les différents résultats obtenus par les algorithmes que nous avons développés.

Nous terminerons ce mémoire par une conclusion générale qui résume les méthodes développées et les résultats obtenus. Ainsi, nous mentionnerons quelques perspectives qui peuvent enrichir ce travail.

Chapitre 1 :

Aspect médical

I.1 Introduction

Le système digestif, également connu sous le nom gastro-intestinal (GI), englobe les organes impliqués dans la digestion. Ce système peut être affecté par diverses pathologies, certaines sont légères qui peuvent parfois être détectées facilement et traitées par des médicaments simples. Dans des cas plus graves et compliqués, le diagnostic est plus difficile et le traitement nécessite des interventions chirurgicales. Des prévalences récentes indiquent une augmentation du nombre de personnes touchées par les maladies gastro-intestinales. Grâce aux progrès technologiques de l'imagerie médicale et de l'informatique, les chercheurs ont réalisé des avancées significatives dans la détection et le suivi de ces pathologies.

Le but de ce chapitre est de fournir un aperçu médical sur la problématique que nous allons traiter dans ce travail. Tout d'abord, nous allons décrire en détail l'anatomie et la physiologie du système digestif, ainsi que le mécanisme des pathologies gastro-intestinales qui peuvent affecter ce système, en concentrant sur celles qui nous intéressent dans ce projet. Ensuite, nous aborderons les divers examens cliniques utilisés pour l'exploration, le diagnostic et le suivi des pathologies gastriques. Enfin, nous concluons notre chapitre.

I.2 Le système digestif

Le système GI englobe l'ensemble des organes qui interviennent dans la transformation des aliments en nutriments assimilables par l'organisme et dans l'élimination des déchets solides [1]. Il est composé de deux parties : le tube digestif et les annexes. La figure I.1 suivante montre les composants du système GI.




Figure I.1: Le système digestif.

Dans ce qui suit, nous allons décrire l'anatomie et la physiologie de chaque partie séparément.

I.2.1 La cavité buccale et son contenu

Anatomie

I.2.1.1 Cavité buccale

Elle représente l'entrée du tube digestif et responsable de la mastication, de la déglutition des aliments à l'aide des dents et de la langue et de l'insalivation à l'aide des glandes. La bouche contient 4 types de dents : les incisives d'un nombre totale de 8, 4 canines, 8 prémolaires et 12 molaires [2]. La figure I.2 ci-dessous représente les différents composants de la cavité buccale.

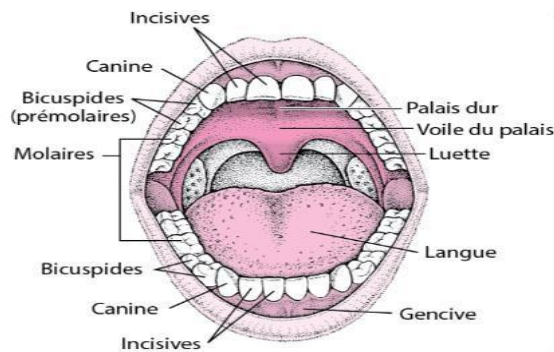


Figure I.2 : la cavité buccale.

I.2.1.2 Les glandes salivaires

Le rôle de ces glandes est la production de la salive qui aide à humidifier la nourriture afin de pouvoir l'avaler facilement. La salive produit l'amylase qui décompose l'amidon provenant des aliments. Il existe 3 types de glandes : la parotide située devant les oreilles, la sous-maxillaire située derrière la mâchoire et la sublinguale à côté de la langue (figure I.3) [3].




Figure I.3 : les glandes et les canaux salivaires

Physiologie

Amylase salivaire est un enzyme responsable de la dégradation d'amidon dans la bouche. Les féculents et les autres glucides digestibles non digérés par cet enzyme sont dégradés par l'amylase pancréatique [4].

I.2.2. Le tube digestif

C'est une suite d'organes reliés entre eux formant le chemin du passage de la nourriture. Il regroupe : l'œsophage, l'estomac, l'intestin grêle, le gros intestin et le rectum.

I.2.2.1 L'œsophage

Anatomie

L'œsophage est un conduit souple et musclé qui transporte la nourriture. Il se situe derrière la trachée et se confond avec celle-ci à travers l'adventice. Sa longueur est d'environ 23 à 25 cm et il prend naissance à l'extrémité inférieure de l'hypopharynx. Il traverse ensuite le médiastin devant la colonne vertébrale, avant de passer à travers le diaphragme par le hiatus œsophagien pour se connecter à l'estomac au niveau du cardia.

Physiologie

L'œsophage n'a pas de sécrétion enzymatique et de rôle d'absorption. Son rôle principal est d'acheminer les aliments vers l'estomac. La paroi de cet organe est tapissée de mucus sécrété par les glandes œsophagiennes, qui la protège contre les dommages abrasifs des aliments, les brûlures et les acides gastriques. Les muscles lisses de l'œsophage sont responsables de la contraction et de relâchement des muscles pour faire progresser le bol alimentaire vers l'estomac. [5].

I.2.2.2 L'estomac

Anatomie

L'estomac est un organe creux situé dans la cavité abdominale, principalement du côté gauche, et partiellement recouvert par le diaphragme et le foie. Il mesure environ 25 cm de longueur et 10 à 15 cm de largeur [5]. L'estomac peut être divisée en 5 régions principales :

- a. Le cardia : est la partie supérieure, elle reçoit la nourriture provenant de l'œsophage. A ce niveau-là, se trouve le muscle strié appelé sphincter cardiaal son rôle est de prévenir le reflux gastrique.
- b. Le fundus : c'est la ou les aliments sont temporairement stockés.
- c. Le corps de l'estomac : est la troisième région, elle est responsable de la digestion chimique par les enzymes.
- d. L'antre pylorique : est une région étroite dans la partie inférieure. Elle conserve les aliments digérés jusqu'à ce qu'ils soient prêts à être évacués dans l'intestin.
- e. Le pylore : est la dernière région de l'estomac, il relie l'estomac avec l'intestin grêle [5].

La figure I.4 qui suit montre l'anatomie de l'estomac avec ses différentes régions.




Figure I.4 : Anatomie de l'estomac.

Physiologie

Physiologiquement, l'estomac assure la digestion des aliments en utilisant deux types de digestions : mécanique et chimique.

- La digestion mécanique : les muscles de la paroi de l'estomac se contractent pour mélanger les aliments avec les sécrétions gastriques (enzymes). Cette action forme un mélange appelé « chyme gastrique ». Ce dernier est ensuite évacué à travers le pylore vers l'intestin grêle.
- La digestion chimique : est assurée en utilisant des sécrétions gastriques. Dans cette partie nous présenterons les rôles de ces sécrétions :
 - i. L'acide chlorhydrique : est essentiel pour détruire les microbes, dénaturer les protéines et stimuler la sécrétion des hormones de régulation.
 - ii. Les enzymes nécessaires pour la dégradation des protéines en acides aminés commencent dans l'estomac grâce à l'action d'un groupe d'enzymes appelé la pepsine. Celle-ci fonctionne dans un environnement extrêmement acide, avec un PH compris entre 1,5 et 2,5.

L'estomac est protégé de cette acidité par des cellules à mucus [5].

I.2.2.3 L'intestin grêle

Anatomie

L'intestin grêle est un conduit de 6 à 7 mètres avec un diamètre de 2,5 cm commence après le pylore jusqu'à la valvule iléo-cæcale. Il est situé dans la région abdominale entre l'estomac et le colon [5]. Il est subdivisé en 3 parties :

- a. Le duodénum : représente la première partie de l'intestin grêle et mesure environ 25 cm.
- b. Le jéjunum : la partie intermédiaire et mesure environ 2,5 mètres.
- c. L'iléon : la région terminale, il mesure 3,6 mètres de longueur et connecte le début du colon (caecum) par la valvule iléo-cæcale.

Physiologie

- Neutralisation : en premier temps, il neutralise le chyme gastrique à l'aide des glandes de BRUNNER situées au niveau du duodénum.
- Digestion des lipides : lorsque les molécules de graisse sont arrivées dans le duodénum, elles sont enrobées de sels biliaires. Les lipases pancréatiques les dégradent en acides gras et mono-glycérides. La digestion chimique se termine dans l'intestin grêle [4].
- L'absorption : il a une grande capacité d'absorption : de 6 à 8 litres d'eau, d'aliments et les sécrétions grâce à sa surface qui est environ 200 m², et ses villosités (figure I.5). La paroi de l'intestin grêle est riche en vaisseaux sanguins qui assurent le transport des nutriments vers le foie, qui commande leur distribution vers les différents organes, selon les besoins. Les substances non digestibles sont évacuées vers le gros intestin sous forme de liquide et de fibres [7].

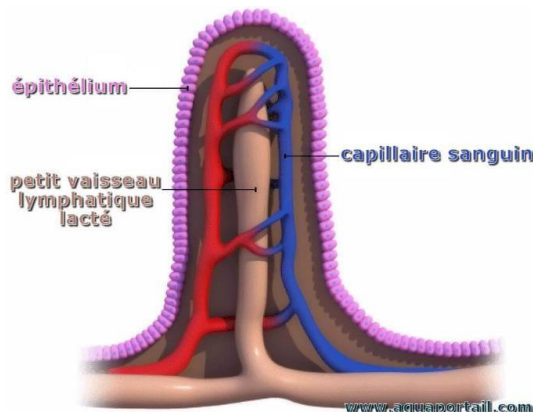


Figure I.5 : villosité intestinale.

I.2.2.4 Le gros intestin

Anatomie

Le gros intestin se compose de cinq parties qui sont :

- **Le caecum** : Premier segment.
- **Le colon ascendant** : Situé dans la partie supérieure droite de l'abdomen, commence à partir du caecum jusqu'à l'angle hépatique du colon, au niveau du foie.
- **Le colon transverse** : Traverse la partie supérieure de la cavité péritonéale.
- **Le colon descendant** : Situé dans la partie inférieure gauche, jusqu'au bassin.
- **Le colon sigmoïde** : Dernier segment du gros intestin.

L'anatomie et la composition du gros intestin est résumée dans la figure I.6.




Figure I.6: le gros intestin.

Physiologie

Son rôle est d'absorber seulement l'eau et les vitamines par la flore bactérienne. Les nutriments sont déjà absorbés par l'intestin grêle.

I.2.2.5 Le rectum

Le rectum est la partie terminale du tube digestif. Il commence du côlon sigmoïde jusqu'au canal anal. En général, sa longueur moyenne est de 12 cm [8].

I.2.3 Les annexes

Le rôle de ces organes est la production des enzymes qui sont des catalyseurs biologiques. Ils participent à la digestion chimique des aliments pour la dégradation des grosses molécules en éléments simples, facilement absorbables par les cellules du tube digestif.

I.2.3.1 Le foie

Anatomie

Le foie est divisé en quatre lobes : hépatique droit et hépatique gauche, entre ces deux lobes, se trouve le lobe carré et le lobe caudé (figure I.7).

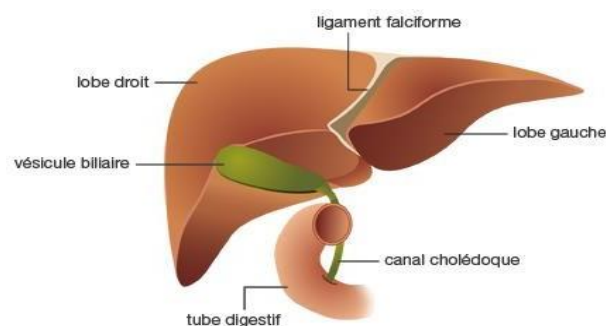


Figure I.7 : anatomie du foie et de la vésicule biliaire.

Physiologie

Le foie joue deux rôles majeurs pendant la digestion : Il reçoit le sang oxygéné de l'artère hépatique et de la veine porte hépatique, qui apporte les nutriments provenant de l'intestin

grêle. Il mélange le sang artériel et veineux et permet ainsi aux cellules hépatiques d'extraire l'oxygène, les nutriments et les substances toxiques du sang [9].

La production de bile assure l'émulsification des lipides, elle agit comme le savon à vaisselle pour diviser les graisses en plus petits morceaux. Le but de cette transformation est de faciliter la dégradation des graisses en molécules simples. La bile est composée d'eau, de cholestérol, de sels biliaires et de bilirubine, qui provient de la dégradation des vieux globules rouges et qui est transformée en protéines [10].

I.2.3.2 Le pancréas

C'est une glande mixte (c'est à dire endocrine et exocrine à la fois). Il joue un rôle important dans la digestion. Le pancréas sécrète et déverse dans l'intestin grêle des enzymes nécessaires pour la dégradation de tout type de substance présente dans les aliments [4].

I.3 Les pathologies gastriques

Plusieurs maladies peuvent affectées le système digestif ou ses annexes dû à des infections, inflammations ou lésions. Dans les sections ci-dessous, nous allons définir les pathologies digestives les plus fréquentes.

I.3.1 Reflux gastro-œsophagien (RGO)

Cette pathologie correspond au retour du contenu gastrique dans l'œsophage à travers un mauvais fonctionnement du cardia qui devrait normalement empêcher ce reflux. Les symptômes du RGO incluent une sensation de brûlure et douleur œsophagienne, des régurgitations acides, une toux nocturne. Cette pathologie peut être causée par un dysfonctionnement du sphincter œsophagien inférieur, une hernie hiatale, une hypertension abdominale ou des antécédents de chirurgie gastrique. Des médicaments ou des toxiques peuvent également être l'origine de cette pathologie [13].

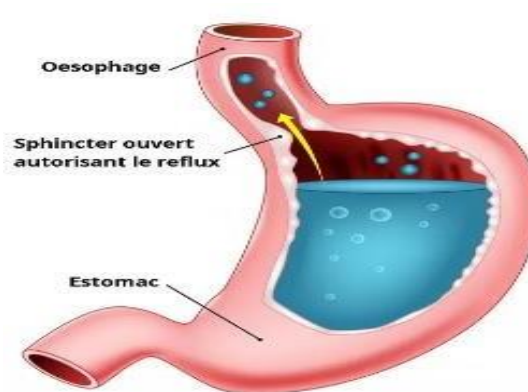


Figure I.8 : RGO gastro- œsophagien.

I.3.2 L'œsophagite

L'œsophagite est une inflammation de la muqueuse de l'œsophage. Elle peut être divisée en 6 formes :

- Œsophagite peptique : complication du RGO qui cause la remonte des acides gastrique vers l'œsophage.
- Œsophagite caustique : causée par une ingestion de produits chimiques comme l'acide ou l'eau de javel.
- Œsophagite médicamenteuse : causée par les grosses molécules des médicaments solides qui prennent une longue durée pour passer vers l'estomac [11].
- Œsophagite radique : suite d'une radiothérapie.
- Œsophagite infectieuse : causée par une infection bactérienne, virale ou fongique (champignons).
- Œsophagite éosinophile : suite d'un dérèglement des éosinophiles (globules blancs), dans l'œsophage [11].

Les symptômes caractéristiques de cette pathologie incluent une douleur thoracique, des difficultés ou des douleurs à avaler, un goût désagréable dans la bouche, une toux, une gêne respiratoire, ainsi qu'une sensation de corps étranger dans la gorge. Cette pathologie peut causer des complications graves telles que le rétrécissement de la partie inférieure de l'œsophage et peut conduire aussi à un œsophage de BARRETT ou un cancer [11].



Figure I.9 : l'œsophagite diagnostiqué par une endoscopie.

Le traitement proposé pour cette maladie dépend de sa cause et de son type : le traitement du type peptique est similaire à celui du reflux gastro-œsophagien (les inhibiteurs de la pompe à proton). L'œsophagite caustique n'a pas de traitement spécifique, mais il est important de consulter un médecin rapidement. L'œsophagite infectieuse peut être traitée par des antibiotiques ou des antiviraux. Enfin, une alimentation équilibrée peut prévenir les conséquences de cette pathologie [12].

I.3.3 Cancer de l'œsophage

Un cancer peut se développer dans n'importe quelle partie de l'œsophage. Il est caractérisé par une difficulté à avaler, une perte de poids involontaire, douleurs thoraciques. Ce cancer est généralement causé par un reflux gastro-œsophagien (RGO) non traité, tabagisme, Œsophage de BARRETT et la consommation de l'alcool [14]. Il est dû à des facteurs génétiques qui entraînent une croissance cellulaire anormale dans la paroi de l'œsophage. Le traitement du cancer de l'œsophage dépend du stade de la maladie.

I.3.4 L'œsophage de BARRETT

Le syndrome de BARRETT est une métaplasie, c'est-à-dire les cellules qui tapissent normalement l'œsophage sont remplacées par des cellules ressemblant à celles qui tapissent l'intestin. Cette maladie est due à un RGO chronique. Elle se caractérise par des symptômes tels que des nausées, des éructations, des douleurs gastriques et une dysphagie [15]. Pour le traitement, l'endoscopie est parfois utilisée pour retirer les cellules endommagées.

I.3.5 Le cancer de l'estomac

C'est un adénocarcinome (déclenche des cellules glandulaires) de l'estomac [16]. Il se manifeste par des symptômes courants tels que des nausées, des vomissements, des douleurs ou brûlures épigastriques. La gastrite chronique, le tabagisme, l'alcoolisme, une mauvaise alimentation et les antécédents familiaux de cancer de l'estomac sont les causes les plus connues pour ce type de cancer. Le traitement inclut la chimiothérapie, radiothérapie, et la chirurgie, tout ça dépend de plusieurs facteurs, le stade, la localisation, et l'état du patient.

I.3.6 Les polypes

Les polypes représentent des petites excroissances qui se développent sur les muqueuses des lumières des organes creux (tube digestif, larynx...). Les polypes colorectaux sont ceux qui se développent dans le colon et peuvent varier en taille, allant de quelques millimètres à plusieurs centimètres. Selon leur taille, ils sont classés en trois catégories : les polypes minimes (inférieurs à 5mm), les polypes petits (entre 6 et 9mm) et les polypes grands (supérieurs à 9mm) [17].

La cause exacte des polypes coliques est inconnue, mais les facteurs génétiques, l'hérédité, les antécédents familiaux et les maladies chroniques jouent un rôle dans leur apparition. Une mauvaise alimentation peut également augmenter le risque de polypes [18].

En général, les polypes ne produisent pas de symptômes particuliers, mais leur présence peut être indiquée par des signes tels que des crampes, des douleurs abdominales ou des saignements colorectaux.

Le diagnostic des polypes est généralement effectué en utilisant l'endoscopie afin de faire une biopsie qui examine le type histologique du polype avec la possibilité d'existence des cellules cancéreuses (figure I.10).




Figure I.10 : image endoscopique d'un polype.

Pour le traitement des polypes, la résection endoscopique reste la référence recommandée. La procédure commence par l'injection d'un liquide sous le polype, soulevant ainsi le polype du tissu sous-jacent. Puis il est extrait par un instrument en forme de boucle en fil (figure I.11). Ensuite, un liquide colorant spécifique pour les mucosectomies larges (comme indigo carmin) est utilisé pour mieux détecter les repères du polype et s'assurer s'il est complètement enlevé ou non.



Figure I.11 : Polypectomie.



(a)



(b)

Figure I.12 : opérations faites sur les polypes (a)polype coloré ; (b) merge après résection endoscopique.

I.3.7 Le cancer du côlon

Ce type de cancer touche le colon et le rectum [20]. Comme la majorité des cancers, la cause exacte n'est pas connue, mais il existe des facteurs qui augmentent le risque tel que l'âge, l'obésité, la sédentarité et l'alcool. Les symptômes associés à cette maladie comprennent des douleurs abdominales et des saignements rectaux (méléna). Ce cancer peut être traité par une chirurgie (colectomie), chimiothérapie ou une radiothérapie selon le stade de la pathologie.

I.3.8 La colite ulcéreuse

C'est une inflammation chronique du colon caractérisée par la présence d'ulcères sur la muqueuse. Elle commence généralement dans la partie inférieure du côlon et se propage vers le haut. Cette maladie est considérée comme un trouble auto-immune et donc peut entraîner des manifestations extra-intestinales comme les ulcères buccaux, la fièvre et l'inflammation des articulations. Effectivement, la colite ulcéreuse est une pathologie idiopathique dont les causes ne sont pas connues mais le facteur génétique et les bactéries intestinales pourraient contribuer à l'inflammation [21].

Les symptômes de cette pathologie dépendent de la gravité et de la localisation des ulcérations. Cependant, des saignements rectaux, une diarrhée accompagnée de crampes abdominales sont les signes les plus connus.

Le traitement dépend de la gravité de la maladie. Pour réduire les symptômes et traiter la muqueuse, les anti-inflammatoires sont utilisés. Dans les cas plus graves, et si la pathologie ne répond pas aux médicaments, la colectomie est nécessaire [21].




Figure I.13 : La colite ulcéreuse.

I.4 Les moyens d'exploration du système digestif

Avec le progrès technologique en imagerie médicale, plusieurs méthodes d'exploration du système GI sont développées pour le diagnostic, le suivi d'évolution et même le traitement des maladies digestives. Dans cette partie nous allons présenter les examens les plus utilisés.

I.4.1 L'endoscopie

L'endoscopie digestive est une technique médicale qui permet d'explorer visuellement et en temps réel le tube digestif en utilisant un endoscope. Ce dernier est un dispositif soit rigide et métallique ou bien souple et constitué de fibres optiques. Cette technique peut être utilisée à la fois pour le diagnostic de certaines pathologies telles que les cancers, les ulcères et les polypes, ainsi que pour la thérapie, en permettant l'exérèse de polypes ou la réalisation de soins locaux. L'endoscope est introduit dans le corps par le gastro-entérologue qui envoie de l'air pour écarter les parois du tube digestif et faciliter l'exploration. Grâce à une caméra, le médecin peut ainsi observer l'intérieur du tube et, si nécessaire, effectuer des prélèvements et des soins avant de retirer l'endoscope. [22]. Cet examen est généralement réalisé en utilisant deux types de matériaux :

- L'endoscopie souple : appelée fibroscopie, est formée d'est un tube souple de longueur de 40 à 160 cm et de 5 à 12 mm de diamètre. Elle est composée de [23] :
 - Un système mécanique de béquillage : permet de modifier l'angle de visée grâce à un système de commande.
 - Canaux opérateurs : pour introduire des instruments chirurgicaux nécessaires.
 - Deux types de fibres optiques : la première fibre transporte la lumière froide de la source jusqu'à la cavité à examiner. Cette lumière est principalement produite par la transformation de l'énergie électrique en lumière (LED) sans dégagement de chaleur. Le but d'utilisation de cette lumière est d'éviter l'endommagement des tissus. Le second type de fibre récupère la lumière de la cavité examinée et la conduit devant le système optique.



Figure I.14 : Endoscope flexible.

- L'endoscopie rigide : utilise un tube métallique qui mesure de 100 à 300 mm de longueur et de 3 à 10 mm de diamètre, actuellement autoclavables. Elle est composée de [24] :
 - Une gaine métallique d'où à l'intérieur se trouve une succession de lentilles.
 - Une source de lumière froide des fibres optiques permettant la transmission de cette lumière.

- Une caméra : est fixée sur l'oculaire et liée à un écran, pour pouvoir explorer la région.
- Un canal interne dans le tube : permet l'introduction d'une pince à biopsie si nécessaire.




Figure I.15 : Endoscope rigide.

L'endoscopie est contre-indiquée pour les patients qui ont des troubles de la coagulation sévère ou cardiorespiratoires.

I.4.2 Abdomen sans préparation ASP

C'est une radiographie simple de l'abdomen réalisée en prenant des images de face et de profil. Son but est d'observer la transparence et l'apparence des organes abdominaux tels que l'intestin, l'estomac et les reins, ainsi que leurs contenus. Le médecin demande cet examen pour comprendre l'origine des douleurs abdominales, les troubles liés à la digestion ou pour les examens de suivi après les interventions chirurgicales [25].

I.4.3 Transit du grêle

Cet examen utilise un produit de contraste appelé sulfate de baryum (BaSO_4), afin d'explorer l'intestin grêle par les rayons X. Ce produit est administré en grande quantité où le patient prend 300 ml de produit de contraste concentré à 30% par voie orale. Cette quantité importante permet d'obtenir une image de l'intestin grêle avec une distension des anses intestinales (Augmentation du volume ou de la taille des boucles de l'intestin grêle) [26].

I.4.4 Lavement baryté

La coloscopie virtuelle est un examen d'imagerie radiographique employant des rayons X pour visualiser le gros intestin et le rectum. Pour opacifier la zone d'intérêt, un produit de contraste contenant du sulfate de baryum est introduit dans le corps par voie rectale. Ce produit progresse à travers tout le colon et adhère aux parois, ce qui permet leur visualisation sur les radiographies grâce à ses propriétés radio-opaques. Cet examen est indiqué dans le cas des douleurs abdominales, des saignements, et pour détecter les cancers et les polypes du colon [27]. La figure I.16 suivante illustre une image coloscopique en utilisant le lavement baryté.



Figure I.16 : Lavement baryté.

I.4.5 Echographie

L'échographie abdominale permet l'exploration des organes annexes du système digestif. Elle donne la possibilité de visualiser les changements morphologiques qui peuvent survenir, tels que la modification d'épaisseur de la paroi. Les sondes utilisées sont la sonde linéaire de fréquence 7,5 à 10 MHz et la sonde convexe de fréquence 3,5 MHz. Son utilisation pour l'exploration du tube digestif reste limitée à cause des zones aériques [28].

Cette technique peut être utilisée pour détecter des tumeurs, des gastrites, des calculs biliaires ou des kystes, ainsi que des signes d'inflammation ou d'infection dans les organes du tube digestif.

I.4.6 Tomodensitométrie (TDM) :

Le scanner ou la tomodensitométrie est un examen d'imagerie médicale qui permet l'exploration des organes sous forme de tranches successives en appliquant les rayons X. Les images obtenues sont ensuite analysées par un ordinateur qui calcule les différents coefficients d'absorption des tissus des organes [29]. Cette technique est couramment utilisée pour explorer les organes abdominaux, détecter les sténoses, les hernies hiatales ainsi que les tumeurs.



Figure I.17: Scanner abdominopelvien.

I.4.7 Colonographie par TDM

La coloscopie virtuelle ou colonographie par TDM est une méthode d'imagerie qui utilise un scanner multi-détecteurs pour obtenir des images bidimensionnelles et tridimensionnelles du côlon. L'examen consiste à injecter un produit de contraste avant de passer une TDM abdominopelvienne, les images en 3D obtenues permettent de détecter les anomalies existantes dans le colon (figure I.18) [30].



Figure I.18 : Colonographie.

I.4.8 Imagerie par Résonance Magnétique (IRM)

L'imagerie par résonance magnétique, comme son nom l'indique, repose sur le principe de la résonance magnétique nucléaire. Elle applique des ondes électromagnétiques sur une zone du corps, puis mesure le signal renvoyé par les atomes d'hydrogène. Cette détection permet de différencier les tissus des organes [29]. Elle est souvent utilisée chez les patients plus jeunes qui subissent des inflammations intestinales pour minimiser leur exposition aux rayonnements tout au long de leur vie. Cependant, cette méthode est plus onéreuse que l'entérographie par TDM [30].



Figure I.19 : Image IRM abdominale.

I.4.9 Laparoscopie (cœlioscopie)

La laparoscopie peut être utilisée pour diagnostiquer des pathologies gastriques en permettant une visualisation directe des organes abdominaux en cas de douleurs chroniques ou aiguës. Le principe de la technique est d'introduire une caméra par de petites incisions au niveau de l'abdomen, après avoir gonflé l'abdomen avec du CO₂. En introduisant des instruments chirurgicaux dans des ouvertures séparées, une biopsie peut être effectuée afin d'examiner les tissus et la possibilité de l'existence de cellules cancéreuses. Après l'examen, la manœuvre de Valsalva permet d'expulser le CO₂ [31].




Figure I.20 : Laparoscopie.

Conclusion

En gastro-entérologie, l'endoscopie digestive est la technique d'imagerie médicale principale pour explorer la paroi interne du tube digestif en temps réel et détecter diverses pathologies, ainsi que pour effectuer des interventions chirurgicales.

Dans ce chapitre, nous avons commencé par une description du système digestif et le mécanisme de son fonctionnement. Ensuite, nous avons présenté les pathologies les plus courantes qui peuvent l'affecter, en mettant l'accent sur les trois pathologies qui nous intéressent dans ce mémoire (l'oesophagite, les polypes gastriques et la colite ulcéreuse). Enfin, nous avons abordé les différents moyens d'imagerie médicale employés pour le diagnostic et l'exploration du système digestif, en soulignant le rôle primordial de l'endoscopie digestive.

Chapitre 2 :

Etat de l'art et principe d'Apprentissage profond

II.1. Introduction

L'intelligence artificielle, et plus particulièrement les modèles d'apprentissage profond, sont de plus en plus utilisés dans le domaine médical pour le diagnostic et le suivi thérapeutique de diverses pathologies. Ces techniques permettent de traiter efficacement de grandes quantités de données médicales complexes, telles que les images médicales 2D et 3D, en identifiant les caractéristiques subtiles qui ne sont pas facilement détectables par les médecins. La détection précoce des pathologies est devenue une tâche facile par l'utilisation de ces techniques, ce qui peut améliorer les résultats pour les patients en termes de précision de diagnostic et de temps de réponse pour le traitement, notamment dans le domaine de la gastrologie.

Dans ce chapitre, et dans un premier temps, nous présenterons une perspective historique sur l'évolution des recherches portant sur la classification des pathologies gastriques détectées par l'endoscopie. Ensuite, nous décrirons les outils et méthodes que nous allons utiliser pour mener à bien notre travail.

II.2. L'état de l'art

Récemment, plusieurs travaux ont été développés pour la détection des pathologies gastro-intestinal à partir des images endoscopiques. La majorité de ces méthodes sont basées sur l'utilisation des modèles de deep learning. Parmi eux nous citerons :

Zenebe Markos Lonseko et al. [32] ont utilisé un réseau de neurones à convolution (CNN) guidé par l'attention pour déterminer les régions d'intérêt nécessaires pour la classification d'une image endoscopique. Pour l'entraînement, les auteurs ont utilisé une base de données d'images endoscopiques possède 13 pathologies gastriques différentes. A la fin ils ont obtenu une précision de 92,84%.

Un autre travail réalisé par Timothy Cogan et al. [33] qui est basé sur un modèle d'apprentissage en profondeur pour identifier les anomalies dans les images endoscopiques à haute résolution. Au début, ils ont appliqué un prétraitement d'images en employant l'algorithme de MAPGI (modular adaptive preprocessing for gastrointestinal tract images). Ensuite, les architectures inception(acc98,45%), et NASNet(97,48%) sont utilisées pour détecter les maladies.

Şaban Öztürk et al. [34] ont combiné des couches de réseaux de neurones convolutifs (CNN) avec plusieurs classifieurs tels que : les réseaux de neurones récurrents (LSTM), machine à support de vecteur (SVM), et les réseaux de neurones artificiels (RNA) pour l'extraction des paramètres et la classification des pathologies à partir des images

endoscopiques. La précision finale a donné une précision maximale de 97.90% pour l'architecture de réseau de neurones récurrents LSTM.

Gammele et al. [35] ont développé une méthode qui utilise deux réseaux de neurones convolutifs en parallèle pour extraire les caractéristiques à partir des images 2D et des séquences d'images (vidéos) 3D. Les caractéristiques sont ensuite combinées pour classifier les vidéos en fonction des anomalies détectées. Pour améliorer les performances, ils ont appliqué le réseau de neurones pré-entraîné ResNet50. Les résultats ont montré un taux de classification de 95%.

Dans le travail de Sin-ae Lee¹ et al. [36], la première étape consistait sur le prétraitement des images pour les filtrer. Ensuite, ils ont utilisé des techniques de segmentation d'image basée sur la méthode SLIC (simple linear iterative clustering) et Fast and Robust Fuzzy C-Means (FRFCM). Ils ont proposé une architecture de réseau de neurones du model xception qui permet la classification des images, ils ont atteint une précision de 96%.

Un autre travail a été développé par Quoc-Huy Trinh et al. [37]. Les auteurs ont proposé une architecture Dense-ResNet, qui combine les architectures ResNet et DenseNet. Le but de cette combinaison est d'obtenir de meilleures performances pour la classification d'images endoscopiques. Ils ont atteint une précision de 92,63%.

Imran Iqbal et al. [38] ont utilisé une approche basée sur l'extraction de caractéristiques à partir des images endoscopiques. Ils ont développé une architecture de CNN profond, appelée Human Gastrointestinal tract Abnormalities Network (HGANet) qui combine deux architectures de plusieurs blocs. HGANet est utilisé pour détecter et classifier les anomalies gastriques. Ils ont obtenu une précision de 97.43%.

Yan Wen et al. [39] ont proposé une méthode pour améliorer la segmentation de polypes dans les images de coloscopie en utilisant des réseaux de neurones entièrement convolutifs (FCN). Ils ont utilisé un réseau pré-entraîné pour l'extraction des poids puis entraînement du modèle sur des images annotées spécifiques à la tâche de segmentation de polypes. Cette technique a introduit une nouvelle méthode pour ajuster la taille du noyau de convolution pour améliorer les performances de segmentation. Les résultats expérimentaux ont montré que l'approche a donné une précision de 96.38%.

Un autre travail est réalisé par Zenebe Markos Lonseko et al. [40] pour effectuer la segmentation des anomalies gastriques. Le travail consiste à faire une segmentation semi-supervisée en utilisant à la fois des données étiquetées et non étiquetées pour améliorer la performance de la segmentation tout en réduisant les besoins en données annotées. La précision finale du système atteint 89.42% \pm 3.92.

Sheng Li et al. [41] ont proposé une méthode de classification d'images intestinales à l'aide d'un réseau de neurones à attention multi-échelle (MFE). La méthode fusionne les hautes et les basses caractéristiques de l'image pour avoir une meilleure précision de classification. Le réseau utilise également une technique d'attention pour mettre en évidence la région d'intérêt des images endoscopiques. Ils ont atteint une précision de 98%.

II.3. L'intelligence artificielle (IA)

L'IA est une discipline de l'informatique qui implique l'utilisation d'algorithmes sophistiqués et de modèles mathématiques pour développer des systèmes capables de simuler certaines formes d'intelligence humaine, comme la reconnaissance d'images, la traduction de langues, le traitement du langage naturel, la classification et d'autres tâches similaires. Ces systèmes utilisent des modèles mathématiques complexes pour interpréter les données et prendre des décisions autonomes, ce qui pourrait avoir des implications importantes dans de nombreux domaines, notamment la médecine et la détection des pathologies.

II.4 L'apprentissage automatique

Nommé aussi "Machine Learning" introduit en 1959 [42]. C'est une branche de l'IA qui utilise des algorithmes qui permettent à un modèle d'apprendre automatiquement à partir d'un ensemble de données et effectuer des prédictions basées sur ces modèles. Les algorithmes d'apprentissage automatique sont classés en trois catégories selon la disponibilité ou non d'étiquettes dans les données : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage semi-supervisé.

II.4.1 L'apprentissage supervisé

Les données utilisées pour entraîner le modèle sont préalablement étiquetées par un expert, ce qui signifie que chaque exemple de données est associé à une étiquette. Le but est de créer un modèle qui peut prédire correctement les étiquettes des nouvelles données qui n'ont pas encore été vues par le modèle. Le processus d'apprentissage supervisé se déroule en deux phases : une phase d'apprentissage où le modèle est entraîné sur une partie des données étiquetées, suivie d'une phase de test où ce modèle est évalué sur de nouvelles données pour prédire correctement les classes des données non étiquetées.

II.4.2 L'apprentissage non supervisé

Les algorithmes basés sur l'apprentissage non supervisé sont utilisés dans le cas où les données ne sont pas étiquetées. Il incombe donc au système d'extraire des règles de classification pour regrouper les données en fonction de leurs similarités.

II.4.3 L'apprentissage semi-supervisé

Les méthodes semi-supervisées combinent les données annotées et non annotées. Dans ce cadre, les algorithmes apprennent progressivement grâce à une meilleure exploitation des données non annotées [43].

II.5 Le réseaux de neurones artificiels

Le RNA est inspiré du système nerveux humain (figure II.1). Il est composé de nombreuses couches de neurones interconnectés dont une couche d'entrée pour recevoir les données, une ou plusieurs couches cachées pour traiter les informations et une couche de sortie pour présenter les résultats de classification. Chaque neurone a un poids et un biais pour le relie avec les autres neurones [44].




Figure II.1 : Neurone biologique et neurone artificiel.

II.5.1 Le perceptron

Les premiers réseaux de neurones sont connus sous le nom de "perceptron". Ils sont constitués d'une seule couche de neurones et sont principalement utilisés pour la classification binaire. Ces réseaux comprennent N entrées (X_i), pour chaque entrée un poids (w_i) est initialisé aléatoirement, suivis d'une seule couche dans le réseau (comme indiqué dans la figure II.2), puis un seul nœud en sortie du réseau qui prend la somme pondérée des entrées et utilise une fonction d'activation pour déterminer la sortie.




Figure II.2 : Architecture du perceptron.

II.5.2 Les réseaux de neurones artificielles multicouches (MLP)

Les réseaux de neurones multicouches sont généralement plus complexes et contiennent plusieurs couches de neurones dites cachées, ce qui leur permet d'effectuer des tâches plus complexes et donner des résultats plus précis.

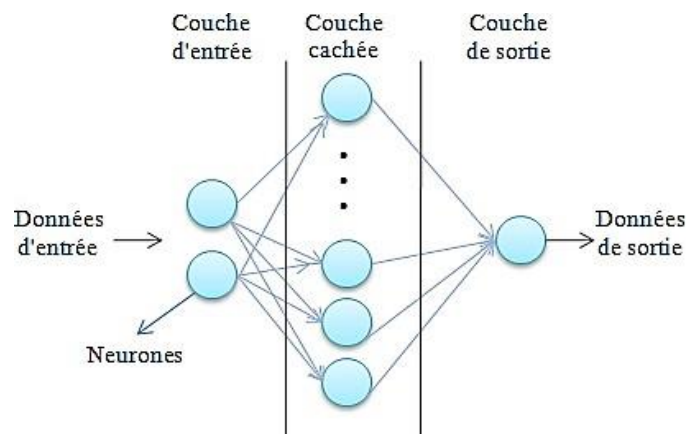


Figure II.3 : Structure de modèle de réseau de neurones artificiels.

Le MLP ont deux applications principales : la classification qui consiste à regrouper des éléments similaires dans la même classe, selon des critères préalablement définis. La régression c'est-à-dire prédire une valeur numérique continue pour une variable de sortie en fonction des variables d'entrée. Chaque application nécessite une phase d'apprentissage et de test (figure II.4). La première phase dédiée à l'entraînement du modèle en utilisant une base de données étiquetée ainsi que des outils informatiques performants telle que la carte graphique (GPU). La deuxième phase est consacrée à l'évaluation du modèle sur d'autres bases de données [45].




Figure II.4 : Les phases dans l'utilisation d'un réseau de neurone artificiel.

II.5.3 L'algorithme de la rétropropagation

Egalement appelé backpropagation est une méthode très utilisée pour l'optimisation et l'ajustement itérative des poids d'un réseau. Elle est basée sur la minimisation de l'erreur entre la sortie réelle et la sortie prédite. Cette dernière est obtenue en calculant la somme pondérée des neurones d'entrées selon une fonction d'activation. En utilisant la propagation de l'erreur dans le sens inverse du réseau, de la couche de sortie vers la couche d'entrée, les poids sont ajustés pour optimiser la généralisation sur de nouvelles données et minimiser l'erreur sur l'ensemble d'apprentissage [46]. La figure II.5 résume le principe de fonctionnement de la rétropropagation.




Figure II.5 : Illustration graphique du processus de la rétropropagation.

II.5.4 La fonction d'activation

La fonction d'activation utilisée dans les réseaux de neurones, est une fonction non linéaire qui permet la classification de données qui ne peuvent pas être séparées linéairement. Cette fonction est inspirée du seuil d'activation que l'on observe dans les neurones biologiques :

lorsque le signal électrique atteint un certain seuil, il excite un message nerveux qui se propage dans les neurones. Il existe plusieurs types de fonctions d'activation, telles que la fonction sigmoïde, ReLu (Rectified Linear Unit), softmax et tanh [47].

II.6 Principe du deep learning

II.6.1 Définition

L'apprentissage profond est un sous-domaine de l'intelligence artificielle basé sur l'apprentissage automatique (figure II.6). Il est une amélioration des réseaux de neurones artificiels (RNA), composés de multiples couches de neurones qui traitent et interprètent les données en cascade [48].

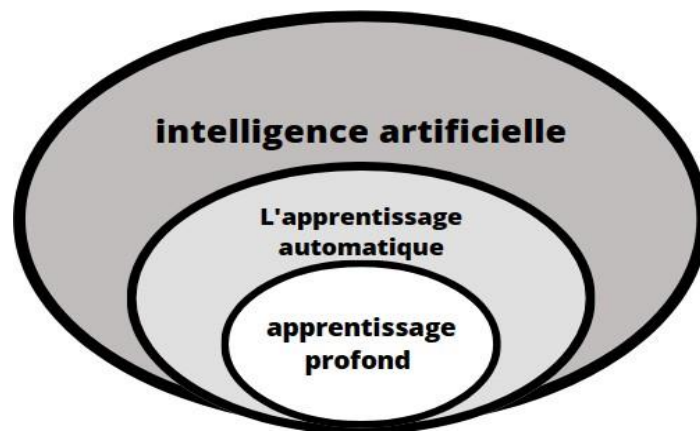


Figure II.6 : La relation entre AI, l'apprentissage automatique et le deep learning.

II.6.2 Réseaux de neurones convolutifs (CNN)

Egalement nommés les réseaux de convolution ConvNet. Ils sont des algorithmes d'apprentissage profond conçus pour traiter des données en deux ou trois dimensions. Ils sont particulièrement adaptés pour traiter des images couleur qui sont constituées de trois matrices contenant les intensités de pixels pour les trois canaux de couleur [49].

Leur avantage par rapport aux outils traditionnels de la classification supervisée est l'extraction automatique des paramètres et des informations pertinentes et ils n'ont pas besoin d'un prétraitement avant d'injecter les données en entrée du réseau.

Pour l'apprentissage, les CNN identifient automatiquement les caractéristiques pertinentes d'image, puis entraînent un classifieur sur la base de ces caractéristiques. Cependant, ce qui distingue les CNN, c'est qu'ils extraient et décrivent des caractéristiques simples dans les premières couches et d'autres plus complexes avec les couches convolutives les plus profondes lors de la phase d'apprentissage. L'erreur de classification est minimisée après chaque itération afin d'optimiser les paramètres du classifieur et les caractéristiques elles-mêmes [50].

Dans les CNN, les poids et les biais sont identiques pour toutes les couches cachées. Cela signifie que les neurones cachés cherchent les mêmes caractéristiques d'une image dans des régions différentes, ce qui permet d'avoir une présentation des caractéristiques locales pour avoir des informations sur les objets globaux présents dans l'image [51].

II.6.3. L'architecture d'algorithmme

Un CNN peut comporter de nombreuses couches, souvent des dizaines voire des centaines, chacune spécialisée dans la détection de caractéristiques spécifiques d'une image. Les images d'apprentissage sont soumises à différents filtres, et la sortie est utilisée comme entrée pour la couche suivante. Les premiers filtres peuvent détecter des caractéristiques très simples, telles que la luminosité et les contours, tandis que d'autres filtres deviennent de plus en plus complexes et spécialisés pour détecter des caractéristiques propres à l'objet en question [51].

Un modèle d'apprentissage profond se compose généralement de quatre couches principales : convolution, pooling, fonction d'activation et couche entièrement connectée.




Figure II.7 : Architecture d'algorithmme de CNN.

Contrairement au MLP qui ne contient qu'une partie pour la classification, les CNN possèdent deux parties distinctes :

- La partie convolutive : son rôle est d'extraire les caractéristiques d'une image en la divisant en plusieurs parties afin de réduire sa taille. L'image traverse plusieurs filtres qui permettent de créer de nouvelles images appelées "cartes de caractéristiques" qui seront concaténées en un vecteur de caractéristiques.
- La deuxième partie : est la partie de classification où le vecteur de caractéristiques obtenu de la partie précédente est transmis à travers les couches entièrement connectées pour effectuer la classification en utilisant la fonction softmax [52].

II.6.4 Les couches du CNN

Un réseau de neurone convolutif se compose de plusieurs couches successives, chacune joue un rôle important dans le processus de classification en identifiant des paramètres spécifiques. Dans ce qui suit, nous allons définir les couches les plus essentielles pour le développement d'un modèle de la classification d'images.

II.6.4.1 La couche de convolution

Cette couche est l'élément clé d'un CNN. Elle consiste à appliquer plusieurs filtres de petite taille sur des portions de l'image en faisant glisser une fenêtre représentant la feature (filtre). À chaque déplacement, le produit de convolution est calculé entre la feature et la portion de l'image balayée (figure II.8). Lors de la conception d'un CNN, la taille et le nombre total des filtres et le pas de convolution sont fixés au départ pour chaque couche convolutive.




Figure II.8 : Filtre de convolution.

II.6.4.2 La couche de correction

La fonction d'activation ReLU (Rectified Linear Unit) est couramment utilisée dans les CNN. Elle remplace les valeurs négatives dans la carte de caractéristiques par zéro. Elle est définie par la formule suivante : $\text{relu}(x) = \max(0, x)$, d'où si $x > 0$ retourne x ; sinon retourne 0 [53].




Figure II.9 : Principe de fonctionnement de ReLU.

II.6.4.3 La couche de pooling

La couche de pooling est placée entre deux couches convolutives dans l'architecture du CNN. Elle a pour objectif de réduire la taille spatiale de l'image tout en conservant les informations pertinentes. Cette opération consiste à découper l'image en petites fenêtres de taille fixe (2x2 ou 3x3) pour préserver les informations importantes en conservant que la valeur maximale, ou en calculant la valeur moyenne de chaque fenêtre (max pooling ou average pooling). La sortie de cette couche a le même nombre de paramètres que l'entrée, mais elle est considérablement plus petite. Un avantage important de cette couche est qu'elle est moins sensible à la position des caractéristiques, ce qui signifie que les changements d'orientation ou de positionnement des informations pertinentes n'affectent pas radicalement la classification [54].




Figure II.10 : Exemple de pooling avec les différentes stratégies (maximum, moyen). La taille des fenêtres ainsi que le pas utilisé dans cet exemple sont de 2x2.

II.6.4.4 La couche entièrement connectée " fully connected"

La couche entièrement connectée (FC) représente la dernière couche dans un réseau de neurones, convolutif ou non. La couche FC est connectée à tous les neurones de la couche

précédente. Elle est souvent utilisée à la fin du réseau pour prendre en compte toutes les caractéristiques apprises par les couches précédentes et produire une sortie finale.

Cette couche est généralement suivie par une fonction d'activation Softmax, qui sert à normaliser les sorties du FC en produisant une distribution de probabilité sur les différentes classes possibles dans les tâches de classification multiclasse. Elle prend un vecteur en entrée et produit un nouveau vecteur de taille N , où N est le nombre de classes dans le problème de classification. Chaque élément du vecteur représente la probabilité que l'image appartienne à une classe spécifique. Par exemple, si on a deux classes N et M , le vecteur de sortie $[0.90, 0.10]$ signifie que l'image a 90% de chances de représenter la classe N et 10% de chances de représenter la classe M . La couche Softmax est donc utile pour interpréter la sortie comme une distribution de probabilité et sélectionner la classe de sortie la plus probable [54].




Figure II.11 : Couche entièrement connectée.

II.6.4.5 Les algorithmes d'optimisation

Les algorithmes d'optimisation et de régularisation ont un but d'éviter le sur-apprentissage et l'améliorer la généralisation et l'ajustement des paramètres du modèle pour améliorer sa performance non seulement sur les données d'entraînement, mais également sur les données de test ou de validation. Ces algorithmes visent à minimiser la fonction de coût, qui mesure l'écart entre les prévisions du modèle et les valeurs réelles sur l'ensemble de données d'entraînement. Parmi ces algorithmes nous citerons : SGDM (Stochastic gradient descent with momentum) et ADAM (Adaptive Moment Estimation) [47].

II.7. Transfert learning

Le transfert learning, également appelé apprentissage par transfert, est une technique de machine learning qui consiste à transférer les connaissances acquises par un modèle sur une tâche donnée, pour l'appliquer sur une autre tâche similaire ou connexe. Cela permet à la

machine d'apprendre plus efficacement en utilisant les connaissances préalablement acquises sur des tâches antérieures. En somme, l'apprentissage par transfert permet de mutualiser les connaissances d'un modèle pour améliorer la qualité d'apprentissage d'un autre. Cette approche peut être particulièrement utile lorsque l'ensemble de données pour la nouvelle tâche est limité ou que le temps d'entraînement est coûteux, car elle permet de réduire le temps et les ressources nécessaires pour entraîner un modèle performant [55].




Figure II.12 : Différence entre apprentissage normal et apprentissage par transfert.

En générale, il est mieux d'utiliser un réseau de neurones pré-entraîné à l'aide de l'apprentissage par transfert, car l'utilisation de ces modèles pour la classification nécessitent moins de données (quelques centaines au lieu de millions) et le réseau a déjà été entraîné sur de grandes quantités d'images [51].

II.8 Les modèles de deep learning les plus populaires

Dans cette partie, nous allons définir les architectures des différents réseaux de neurones utilisés dans notre projet de fin d'étude qui sont : AlexNet, VGG16 et VGG19.

II.8.1 AlexNet

Ce modèle a été développé par Alex Krizhevsky et al. [56]. AlexNet est composé de 5 couches convolutives, chacune est suivie par une fonction ReLU, et trois couches de maxpooling. A la sortie, trois couches FC suivies par softmax sont employées pour la classification. Ce modèle a utilisé en 2012 par la compétition ILSVRC (ImageNet Large Scale Visual Recognition Challenge) pour la classification des images.




Figure II.13 : Architecture alexnet.

II.8.2 VGGNet

Son nom signifie Visual Geometry Group (VGG) proposé par A. Zisserman et K. Simonyan de l'université d'Oxford [57]. Ce modèle a gagné la compétition ILSVRC en 2014. Les développeurs ont constaté que la profondeur des couches joue un rôle dans la précision du modèle. Ils ont minimisé les noyaux de convolution de plus petites dimensions (3×3) que ce qui avait été fait jusque-là. Le premier VGG était composé de 16 couches (13 couche de convolution et 3 couches FC) et appelait VGG-16 [58]. Le modèle commence par 2 couches convolutives suivies d'une couche de pooling, puis 2 autres couches convolutives suivies d'une autre couche de pooling. Les 9 couches suivantes sont des couches convolutives chaque 3 sont séparées par une couche pooling. A la fin une fonction softmax sont employées pour prédire la sortie. L'architecture est présentée dans la figure (II.14).



Figure II.14 : L'architecture du VGG 16 ;

La deuxième version appelée VGG19 qui contient 16 couches de convolution, 5 pooling et 3 couches FC. VGG9 se diffère du VGG16 après la 2eme couche de pooling, ce modèle possède 16 couches de convolution, chaque 4 sont séparées par des couches de pooling. A la fin une couche softmax est introduite pour extraire le résultat.



Figure II.15 : l'architecture du VGG 19

II.9 L'évaluation du modèle

L'évaluation quantitative d'un système d'aide au diagnostic médical est cruciale pour prouver l'efficacité et la robustesse du système. Plusieurs métriques d'évaluation peuvent être calculer pendant la phase du test. Ils offrent des informations précises et spécifiques sur la

fiabilité de la technique proposée [59]. La majorité de ces paramètres sont calculés à partir de la matrice de confusion.

II.9.1 La matrice de confusion

La matrice de confusion est un tableau qui résume les résultats de prédiction d'un modèle de classification et permet l'évaluation des performances de la méthode. Dans un cas de classification binaire, il s'agit d'une matrice 2x2, mais il est toujours possible d'ajouter des lignes et des colonnes pour un problème plus complexe.

		Réponse de l'expert	
		p	n
Réponse du classifieur	Y	Vrai Positif	Faux Positif
	N	Faux Négatif	Vrai Négatif

Figure II.16 : La matrice de confusion.

Cette matrice comporte quatre paramètres qui sont :

Vrai positif (VP) : le modèle prédit positif pour une valeur qui est réellement positive.

Vrai négatif (VN) : le modèle prédit négatif pour une valeur qui est réellement négative.

Faux positif (FP) : résultat erroné ou le modèle prédit positif alors qu'il est en réalité négatif.

Faux négatif (FN) : résultat erroné ou le modèle prédit négatif alors qu'il est en réalité positif.

II.9.2 Taux de classification (accuracy) : le taux de classification est donné par la formule suivante :

$$\text{taux de classification} = \frac{vp + vn}{vp + vn + fp + fn}$$

II.9.3 Précision : Précision c'est le rapport entre les vrais positifs et tous les positifs identifiés.

$$\text{Précision} = \frac{vp}{vp + fp}$$

II.9.4 Sensibilité : montre la capacité de prédire les classes réellement positives.

$$\text{sensibilité} = \frac{vp}{vp + fn}$$

II.9.5 La spécificité : indique la probabilité de fausse alarme.

$$\text{la spécificité} = \frac{vn}{vn + fp}$$

II.10 Conclusion

Dans ce chapitre nous avons premièrement présenté un aperçu des travaux qui ont été réalisés dans le cadre de la détection des pathologies gastriques par les différentes techniques de traitement d'image et l'application d'intelligence artificielle.

Deuxièmement, nous avons exposé la théorie des méthodes qui seront utilisées pour détecter les pathologies mentionnées dans le premier chapitre, nous avons commencé par la définition générale de l'intelligence artificielle et expliqué son lien avec le deep learning, tout en présentant les architectures et les modèles les plus connus du deep learning. Nous avons également abordé le sujet du transfert learning et ses avantages dans la classification. Enfin nous avons défini les différentes métriques d'évaluation d'une méthode donnée.

Dans le chapitre suivant, nous allons présenter et interpréter les résultats obtenus à partir des méthodes choisies pour effectuer la détection des pathologies gastriques.

Chapitre 03 :

Résultats et discussion

III.1 Introduction

Les outils de traitement d'image et l'intelligence artificielle jouent un rôle primordial pour la détection des pathologies existantes dans les images endoscopiques. Le deep learning qui représente une branche de l'intelligence artificielle est considéré comme un outils précieux en traitement d'image. Les modèles du CNN pré-entraînés permettent d'extraire automatiquement les paramètres dans les images et classifier les anomalies gastriques. Ce qui permet aux médecins de poser un diagnostic correct et précis.

Dans ce troisième chapitre, nous allons présenter les méthodes utilisées dans le cadre de la détection des pathologies gastriques. Tout d'abord, nous allons exposer les ressources matérielles et les outils employés. Ensuite nous détaillerons les différentes méthodes stratégiques testés avec leurs résultats obtenus. Dans la dernière étape de ce chapitre, nous allons discuter les résultats obtenus et les comparer avec les recherches existantes dans l'état de l'art.

III.2 Matériels et méthodes

III.2.1 Matériel utilisés

III.2.1.1 Base de données :

Dans notre travail nous avons utilisé la base publique Kvasir qui est une base d'images acquise par l'endoscope ScopeGuide de la marque Olympus Europe. Ces images sont collectées à l'hôpital de VestreViken Health Trust en Norvège. Elles sont vérifiées et consultées par des médecins experts en endoscopie.

Cette base est composée de 8 classes, dont trois classes anatomiques (z-line (ligne z), pylore et cecum (caecum)), trois classes pathologiques (œsophagite, polypes et colite ulcéreuse) et deux classes post opératoires. La classe « Dyed and Lifted Polyps », montre un exemple de polype soulevé par injection de liquide coloré, et la classe « Dyed Resection Margins » représente le site de résection après l'ablation d'un polype. Chaque classe contient 500 images couleur RGB avec une taille qui varie entre 720x576 et 1920x1072 pixels. Un exemple de chaque classe est présenté dans la figure III.1.

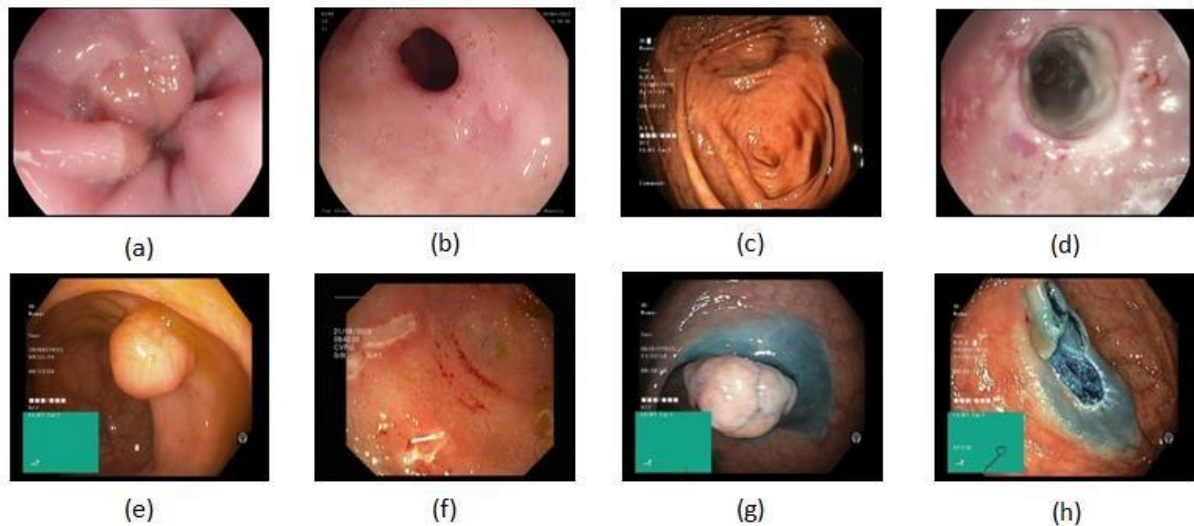


Figure III.1 : Exemple de chaque classe de la base de données KVASIR ; (a): z-line ; (b):pylorus ;(c): caecum ; (d): œsophagite; (e): polype ;(f): colite ulcéreuse ; (g) Dyed and Lifted Polyps(h): Dyed Resection Margins

III.2.1.2 Software et hardware

Le deep learning nécessite une grande base de données et également des ressources matérielles puissantes pour exécuter les calculs intensifs associés à l'entraînement et à l'inférence des modèles. Pour cela, les expérimentations ont été effectuées sur une machine qui offre des performances acceptables d'où le processeur est de marque Intel(R) Xeon (R)W-2102 CPU 2.90Ghz, la RAM 16 Go, la carte graphique (GPU) NVIDIA T1000 et un système d'exploitation windows10 x64bits. Pour le coté Software, nous avons utilisé le langage de programmation Matlab R2022 b.

III.2.2 Les méthodes proposées

Dans cette partie, nous allons commencer par le prétraitement des images, puis nous allons présenter trois méthodes de travail. La première consiste à utiliser un modèle original de CNN. Dans la deuxième partie, nous allons utiliser des modèles préentraînés et l'apprentissage sera réalisé sur une base de donnée augmentée. Dans la troisième partie, les mêmes modèles seront utilisés mais sur les classes originales sans augmentation.

III.2.2.1 Prétraitement des données

Les images de la base de données utilisées contiennent un carré vert qui peut fausser le calcul des paramètres lors de la classification par CNN. Pour remédier à cela, nous avons travaillé sur la suppression de ce carré. La première étape consistait à convertir l'image de l'espace RGB en espace LAB. En appliquant ensuite le seuillage et l'opération

morphologique d'ouverture avec un élément structurant disque de taille (5), cela permet d'éliminer ce carré. Enfin, la dernière étape était de multiplier l'image binaire obtenue avec l'image originale pour récupérer la région d'intérêt. Les résultats de chaque étape sont montrés dans la figure III.2.

Dans notre travail, nous avons utilisé des images couleurs de l'espace RGB car les différentes lésions apparaissent clairement et sont plus visibles par rapport aux images en niveaux de gris.




Figure III.2: Suppression des carrés en vert ; (a) image originale ; (b) image LAB ; (c) : image binaire ; (d) résultat final.

III.2.2.2 l'augmentation des données

Pour améliorer les performances d'un système profond, il est important d'avoir suffisamment de données. Dans le cas du CNN, une grande quantité de données est nécessaire pour avoir une bonne généralisation du modèle et une classification précise d'images.

Cependant, le problème avec les bases de données disponibles sur internet est souvent leur nombre de données insuffisant pour créer un modèle puissant. Cela peut entraîner des performances médiocres du modèle et une mauvaise généralisation.

Pour remédier ce problème, les techniques d'augmentation de données sont souvent proposées comme une solution adaptative pour résoudre le problème de nombre limité de données pour l'entraînement des modèles. Cette technique consiste à appliquer des transformations sur l'image pour avoir de générer de nouvel exemple. Pour réaliser l'augmentation de données, nous avons appliquées plusieurs approches utilisées qui sont :

- **La rotation** : elle consiste à modifier l'angle de l'image, à la faire tourner sur elle-même. Dans le cas d'une image carrée, la rotation de 90° préservera la taille de l'image.
- **L'opération de translation** : cette opération permet de déplacer l'image selon l'axe X et Y

- **L'effet miroir** : représente un retournement selon l'axe horizontal et l'axe vertical.




Figure III.3: Augmentation des données, (a) : image originale; (b): rotation; (c): translation; (d): retournement droit-gauche ; (e) retournement haut-bas.

A la fin de cette partie, nous avons obtenu une base augmentée contenant 24000 images dont 8000 pour chacune des trois classes pathologiques (polypes, colite ulcéreuse et oesophagite). Cette nouvelle base est divisée en 70% apprentissage et 30% test.

III.2.2.3 Classification des pathologies Gastro-intestinales

Dans ce travail, nous proposons un système automatique pour la classification multi-classe des pathologies digestives qui sont : les polypes, l'œsophagite et la colite ulcéreuse.

Pour ce faire, nous avons testé trois expérimentations afin de définir le meilleur modèle. Toutes ces expérimentations sont réalisées par les trois modèles du CNN qui sont AlexNet, VGG16 et VGG19.

- 1 Implémentation des modèles originales sans utilisations de poids pré-entraînés : évaluer la robustesse de notre base de données.
- 2 Implémentation des trois modèles pré-entraînés avec une augmentation de données : vérification de l'impact du transfert learning dans l'amélioration des résultats.
- 3 Implémentation des trois modèles pré-entraînés sans une augmentation de données : validation de l'efficacité de l'étape d'augmentation des images dans l'amélioration des performances d'un réseau de neurones profond et même l'intérêt d'application de grande bases d'images.

Les trois architectures employées dans notre projet de fin d'études sont détaillées ci-dessous.

III.2.2.3.1 AlexNet

AlexNet se constitue de cinq couche de convolution et trois couche de max pooling réparties en trois blocs comme suit : Le premier bloc est composé de 2 couches de convolution chacune est suivie d'une fonction ReLU et une couche de max pooling. Le deuxième bloc contient une seule couche CONV suivie de ReLU puis max pooling. Le

dernier bloc comporte de 2 couches CONV et max pooling. Après, le modèle possède 3 couches FC dont la dernière contient 3 sorties.

Ce modèle nécessite que la taille d'image d'entrée soit $227 \times 227 \times 3$. Il est capable de classer les images en 1000 catégories.

III.2.2.3.2 VGG16

Le modèle VGG16 contient 13 couches de convolution regroupées en cinq blocs. Les deux premiers blocs sont identiques et contiennent 2 couches de convolution CONV de taille 3×3 avec 64 et 128 filtres respectivement. Chaque couche est suivie par la fonction Relu. Les trois autres blocs se composent de 3 couches CONV dont le nombre de filtre est 256, 512 et 512 respectivement. Les blocs sont séparés par une couche de max pooling. A la fin, trois couches FC sont employées avec des valeurs de 4096, 4096 et 3. Ce dernier chiffre indique le nombre de classes à la sortie du modèle. Ces couches sont suivie d'une couche softmax pour la classification.

Ce réseau est entraîné sur plus de 1 million d'objet de la base ImageNet, pour classer les images en 1000 classes. VGG16 nécessite une images d'entrée de taille $224 \times 224 \times 3$.

III.2.2.3.3 VGG19

Il diffère du modèle VGG16 dans les trois derniers blocs de convolution, où chaque bloc est composé de 4 couches de CONV au lieu de 3.

III.2.2.4 Partie expérimentale

Dans cette partie, nous allons présenter les graphes de précision et perte dans les trois modèles utilisés.

III.2.2.4.1 Les paramètres d'apprentissage

Pour optimiser les poids et contrôler le processus d'entraînement des modèles de deep learning, certaines options spécifiques sont souvent utilisées. Le tableau ci-dessous résume les options d'apprentissage utilisées dans notre travail ainsi que le rôle de chaque paramètre. Ces valeurs sont sélectionnées selon la capacité et la mémoire du matériel utilisé.

Le paramètre	Valeur	Définition
Nombre maximal d'époque	6	Nombre d'époques utilisé dans l'apprentissage
Taille de mini-lot	12	nombre d'échantillons d'entraînement utilisés simultanément pour mettre à jour les poids du modèle lors de la descente de gradient.
Taux d'erreur initial	10^{-4}	Taux d'apprentissage initial utilisé lors de l'entraînement d'un modèle de réseau de neurones.
Optimiseur	SGDM	Accélérer la convergence de l'entraînement du modèle en incorporant l'inertie des gradients précédents lors de la mise à jour des poids.
Taille de filtre	3x3	Les filtres de convolution
Fonction de perte	Entropie croisée	Calcul l'erreur entre la sortie réelle et la sortie prédite par le modèle.

Tableau III.1 : les paramètres d'apprentissage

III.2.2.4.2 Les expérimentations

III.2.2.4.2.1 Le modèle non pré-entraîné

Le premier modèle utilisé dans ce travail est le modèle AlexNet non préentraîné. Il s'agit une architecture originale d'AlexNet, c'est à dire n'est pas entraîné auparavant. Dans ce cas, nous avons utilisé la base augmentée. Les résultats d'entraînement sont montrés dans la figure III.6

III.2.2.4.2.1.1 Progression d'entraînement du modèle non pré entraîné

La figure III.4 ci-dessous présente la progression du taux de classification (accuracy) et l'erreur pendant la phase d'apprentissage du modèle Alexnet non préentraîné.

En utilisant ce modèle, nous remarquons l'absence de sur-apprentissage car le tracé noir qui représente la précision de validation et le tracé bleu qui représente la précision d'apprentissage sont presque superposés. Le taux maximal de classification est 87,32%. Le temps d'entraînement a pris environ 662 minutes pour terminer 6 époques.

En outre, nous avons remarque que le taux de classification et le l'erreur convergent correctement, plus l'exactitude tends vers 100%, l'erreur tend vers zéro.

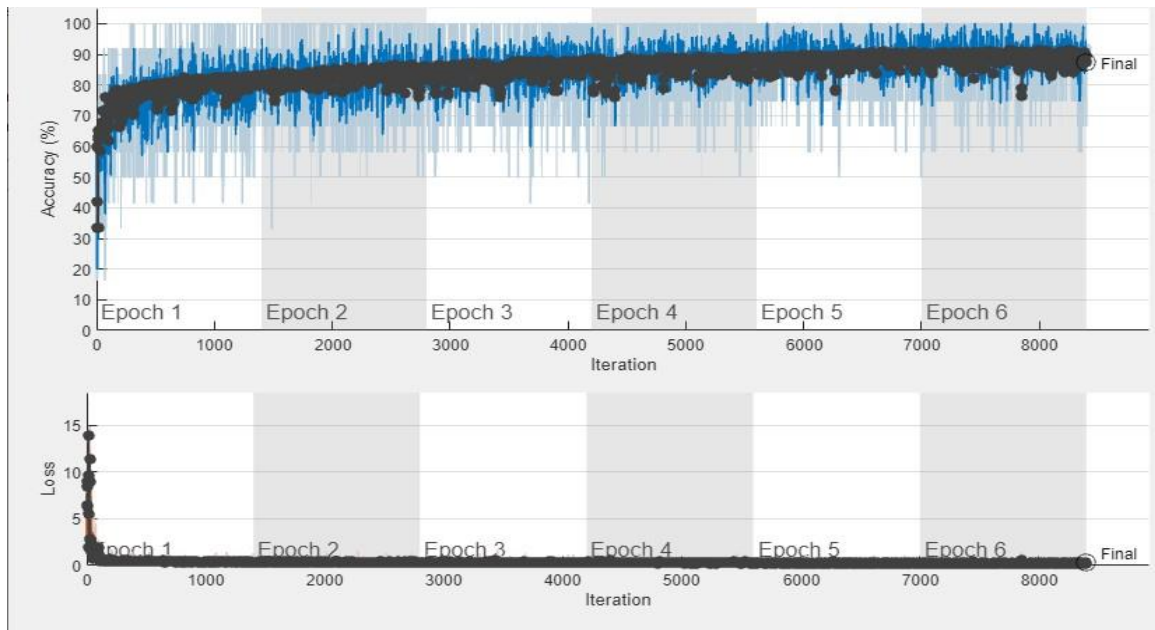


Figure III.4 : Développement de précision et la perte dans le modèle AlexNet non pré entraîné.

III.2.2.4.2.1.2 L'interprétation des résultats de validation

La figure III.5 représente la matrice de confusion des résultats de validation d'après le modèle original AlexNet. Nous pouvons voir les valeurs classifiées correctement et les erreurs dans chaque classe. La majorité des erreurs se trouvent entre la classe des polypes et la classe de la colite ulcéreuse. Le tableau III.2 représente les métriques (précision, taux de classification, sensibilité spécificité) calculées dans chaque classe.

		Confusion Matrix				
		Colite _a lex	Polyps _a lex	oeso _a lex		
Output Class	Colite _a lex	2305 32.0%	71 1.0%	24 0.3%	96.0%	4.0%
	Polyps _a lex	747 10.4%	1584 22.0%	69 1.0%	66.0%	34.0%
	oeso _a lex	0 0.0%	2 0.0%	2398 33.3%	99.9%	0.1%
		75.5%	95.6%	96.3%	87.3%	12.7%
		24.5%	4.4%	3.7%		
		Colite _a lex	Polyps _a lex	oeso _a lex		
		Target Class				

Figure III.5 : la matrice de confusion AlexNet non pré entraîné

La classe	Taux de Classification	Précision	Sensibilité	Spécificité
Polypes	87,6%	95,5%	66,48%	98,48%
Colite ulcéreuse	88 ,31%	75,52%	96,04%	84,44%
Œsophagite	98,68%	96,27%	99 ,92%	98,06%
Moyenne	91,53%	89,1%	87,48%	93,66%

Tableau III.2 : métriques des classes avec le modèle AlexNet non pré entraîné

D’après la matrice de confusion, nous remarquons que la classe d’œsophagite a donné un taux de classification satisfaisant (95%), par contre le cas les autres classes ou le taux était inférieur à 90%.

La précision dans le cas de la colite ulcéreuse est égale à 75% , et la sensibilité dans le cas des polypes est 66,48%. Cela revient au grand nombre des faux positifs et faux négatifs entres ces deux classes.Ces erreurs sont liées à la similarité des fond d’images dans la classe des polypes et de la colite ulcéreuse car les deux pathologies situent dans la meme région anatomique. A la fin de l’interprétation nous pouvons dire que les réseaux non pré entraînés ne donnent pas de bons résultats dans la classification des pathologies gastriques, car les classes sont exposées pour la première fois devant le modèle.

Dans la partie suivante nous allons utiliser des modèles pré-entraînés.

III.2.2.4.2.2 Les réseaux pré entraînés

Dans cette partie, nous allons utiliser le transfert learning qui fournit des modèles de CNN pré entraînés, afin de faciliter l’apprentissage. Ces modèles sont entraînés sur une grande quantité de données avant d’être mis à disposition pour des taches spécifiques. L’avantage principal est le gain du temps et d’effort et l’amélioration de la précision.Nous allons tester trois modèles préentainés AlexNet, VGG16 et VGG19. La différence entre ces modèles est le nombre de couches de convolution. C’est à dire nous allons étudier l’impact

des modèles pré entraînés et le nombre de couches sur la classification des pathologies gastriques

III.2.2.4.2.1 Progression d'entraînement

Dans cette partie, nous allons présenter les résultats d'entraînement des réseaux pré entraînés. En utilisant les 3 modèles pré entraînés AlexNet, VGG16 et VGG19, nous pouvons voir dans chaque cas, que le tracé noir qui représente la précision de validation est superposée le tracé bleu qui représente la précision d'apprentissage. Cela, indique l'absence de surapprentissage. Pour la courbe de perte, nous remarquons que le tracé en rouge (de perte) et le tracé noir sont superposés et tend vers le 0. Cela indique que le système donne un bon résultat avec une bonne généralisation. Le temps d'entraînement change d'un modèle à un autre, il augmente selon le nombre de couche du modèle. Il a pris 1109 minutes pour AlexNet, 5000 minutes dans le cas de VGG16 et 7200 minutes pour le VGG19 avec 6 époques pour chaque modèle. Le taux de classification des trois modèles utilisés dépasse 98%, d'où il est égale à 98,4% pour AlexNet, 99,82% dans le cas du VGG16 et 99,94% pour le VGG19.

- AlexNet




Figure III.6 : La précision et la perte dans le modèle AlexNet pré entraîné

- VGG16




Figure III.7 : la précision et la perte dans le modèle VGG16 pré entrainé

- VGG19




Figure III.8 : la précision et la perte dans le modèle VGG19 pré entrainé

III.2.2.4.2.1.2 L'interprétation des résultats de validation

Nous discutons les résultats de test effectués sur l'ensemble de données de validation. Dans chaque modèle, nous allons présenter les matrices de confusion et calculer les métriques (taux de classification, précision, sensibilité et spécificité). Ensuite, nous allons faire une

première comparaison entre ces différentes méthodes et une comparaison entre nos résultats et les résultats de l'état d'art.

1/ AlexNet

Output Class	Colite _a lex	Polyps _a lex	oeso _a lex	
Colite _a lex	2379 33.0%	21 0.3%	0 0.0%	99.1% 0.9%
Polyps _a lex	91 1.3%	2306 32.0%	3 0.0%	96.1% 3.9%
oeso _a lex	0 0.0%	0 0.0%	2400 33.3%	100% 0.0%
	96.3% 3.7%	99.1% 0.9%	99.9% 0.1%	98.4% 1.6%
	Colite _a lex	Polyps _a lex	oeso _a lex	
	Target Class			

Figure III.9: la matrice de confusion AlexNet pré entraîné

2/ VGG16

Output Class	colite _l cereuse	oesophagite	polyps	
colite _l cereuse	2394 33.2%	0 0.0%	6 0.1%	99.8% 0.2%
oesophagite	0 0.0%	2400 33.3%	0 0.0%	100% 0.0%
polyps	7 0.1%	0 0.0%	2393 33.2%	99.7% 0.3%
	99.7% 0.3%	100% 0.0%	99.7% 0.3%	99.8% 0.2%
	colite _l cereuse	oesophagite	polyps	
	Target Class			

Figure III.10: la matrice de confusion VGG16 pré entraîné

2/VGG19




Figure III.11: la matrice de confusion VGG19 pré entraîné

D'après les matrices de confusion des trois modèles préentraînés et les métriques calculées dans chaque classe, nous résumons ces résultats dans le tableau ci-dessous pour faire une comparaison entre les précisions, les sensibilités et les spécificités dans chaque classe.

La classe	Le modèle	Taux de Classification	Précision	Sensibilité	Spécificité
Polypes	Alexnet	98.4%	99,09%	96,08%	99,56%
	VGG16	99,82%	99,7%	99,7%	99,9%
	VGG19	99,94%	100%	99,8%	99,92%
Colite ulcéreuse	Alexnet	98,44%	96,31%	99,12%	98,1%
	VGG16	99,2%	99,7%	99,8%	99,9%
	VGG19	99,96	99,9%	100%	99,93%
Œsophagite	Alexnet	99,95%	99,8%	100%	99,94%
	VGG16	100%	100%	100%	100%
	VGG19	99,99%	100%	100%	99,98%

Tableau III.3 : métriques des classes de la base augmentée et les modèles pré entraînée

Pour la classe des polypes, les modèles VGG16 et VGG19 ont donné des résultats d'où le taux de classification a dépassé les 99% et une précision maximale.

Dans la classe de la colite ulcéreuse, nous remarquons que quatre paramètres ont une valeur supérieure à 99,9% dans le cas du modèle VGG19. Les résultats les plus médiocres sont présentés sont le cas d'AlexNet.

Pour la troisième classe dans le cas d'œsophagite, les modèles ont donné des valeurs maximales par rapport aux autres classes. Dans le cas du VGG 16 pour les 4 métriques ont des valeurs de 100%.

Les différences entre les classes dans ce cas, dépend de la localisation de la pathologie. Dans le cas d'œsophagite, nous avons eu les meilleures valeurs car cette pathologie touche l'œsophage. Par contre dans le cas de polypes et de colite ulcéreuse, il peut y avoir un chevauchement donc des erreurs de classification, car les deux pathologies se situent dans le même organe.

Pour faire la comparaison entre les modèles préentraînés, nous avons calculé les valeurs moyennes de chaque modèle. Les résultats obtenus sont montrés dans le tableau ci-dessous

	La valeur moyenne			
	Taux de classification	précision	sensibilité	Spécificité
ALEXNET	98,4%	98,4%	98,4%	99,2%
VGG16	99,82%	99,8%	99,83%	99,93%
VGG19	99,94%	99,96%	99,93%	99,94%

Tableau III.4 : métriques moyennes dans chaque modèle

D'après le tableau, nous remarquons que les trois modèles ont donné un taux de classification supérieure à 98%, dans le cas de VGG16 et VGG 19, le taux a dépassé 99,8%.

Nous pouvons dire dans ce cas que le VGG19 est le meilleur modèle par rapport à VGG16 et AlexNet. Parce qu'il contient le plus grand nombre de couche de convolution dans son architecture.

III.2.2.4.2.3 Les réseaux pré entraînés dans le cas de la base sans augmentation

Dans la partie précédente, nous avons utilisé les modèles du CNN dans le cas où la base est augmentée, et nous avons eu des précisions supérieures à 98% dans la majorité des cas.

Nous allons exécuter dans cette partie, les mêmes modèles pré entraînés mais dans le cas où la base de données n'est pas augmentée afin de comprendre l'influence de nombre de données dans la classification par CNN. La base originale contient 1500 images dans ses classes pathologiques. Dans cette partie 1050 images(70%) sont utilisées pour l'apprentissage du système et 450 pour le test.

III.2.2.4.2.3.1 Progression d'entraînement

En utilisant les trois modèles pré entraînés AlexNet, VGG16 et VGG19 pour la classification des cas pathologiques en utilisant la base originale (sans augmentation). Nous observons dans les graphes, que la courbe de précision de validation est en dessous la courbe en bleu représente la courbe de précision de validation. Cela indique le sous apprentissage du système (Under fitting) causé par l'insuffisance de nombre d'images. La position des tracés s'améliore dans les modèles qui possèdent plus de couches de convolution. Le temps d'exécution dans le cas du modèle AlexNet est de 5 minutes, pour le VGG 16 est de 39 minutes et le modèle VGG19 a pris 66 minutes pour l'entraînement. Le taux de classification dans ce cas diffère par rapport au cas précédent, d'où le modèle AlexNet nous a donné 94,89%, le modèle VGG 16 97,11% et 97,78%.

- Alexnet




Figure III.12 : Développement de précision et la perte dans le modèle AlexNet pré entraîné (base sans augmentation)

- VGG16




Figure III.13 :Développement de précision et la perte dans le modèle VGG16 pré entrainé (base sans augmentation)

- VGG19




Figure III.14 :Développement de précision et la perte dans le modèle VGG19 pré entrainé (base sans augmentation)

III.2.2.4.2.3.2 L'interprétation des résultats de validation

Les figures ci-dessous représentent les matrices de confusion des trois modèles préentraînés dans le cas où la base n'est pas augmentée. Le nombre de données n'est pas suffisant pour améliorer la précision du système.

- AlexNet

		Confusion Matrix			
Output Class	colite _s ans _a ug	141 31.3%	2 0.4%	7 1.6%	94.0% 6.0%
	oeso _s ans _a ug	0 0.0%	148 32.9%	2 0.4%	98.7% 1.3%
	polypes _s ans _a ug	11 2.4%	1 0.2%	138 30.7%	92.0% 8.0%
		92.8% 7.2%	98.0% 2.0%	93.9% 6.1%	94.9% 5.1%
		colite _s ans _a ug	oeso _s ans _a ug	polypes _s ans _a ug	Target Class

Figure III.15 : La matrice de confusion du modèle AlexNet dans le cas de la base sans augmentation

- VGG16

		Confusion Matrix			
Output Class	colite _s ans _a ug	145 32.2%	0 0.0%	5 1.1%	96.7% 3.3%
	oeso _s ans _a ug	0 0.0%	149 33.1%	1 0.2%	99.3% 0.7%
	polypes _s ans _a ug	6 1.3%	1 0.2%	143 31.8%	95.3% 4.7%
		96.0% 4.0%	99.3% 0.7%	96.0% 4.0%	97.1% 2.9%
		colite _s ans _a ug	oeso _s ans _a ug	polypes _s ans _a ug	Target Class

Figure III.16 : La matrice de confusion du modèle VGG16 dans le cas de la base sans augmentation

- VGG19




Figure III.17 :La matrice de confusion du modèle VGG 16 dans le cas de la base sans augmentation

La classe	Le modèle	Taux de Classification	Précision	Sensibilité	Spécificité
Polypes	Alexnet	98,89%	93,9%	92%	99%
	VGG16	97,11%	96%	95,3%	98%
	VGG19	97,78%	97,3%	96%	98,67%
Colite ulcéreuse	Alexnet	95,56%	92, 8%	94%	96,33%
	VGG16	97,56%	96%	96,7%	98%
	VGG19	98%	96,1%	96%	98%
Œsophagite	Alexnet	95.33%	98%	98,7%	97%
	VGG16	99 ,56%	99,3%	99,3%	99,67%
	VGG19	99 ,78%	100%	99,3%	100%

Tableau III.5 : métriques des classes de la base sans augmentation et les modèles pré entraînée

D'après les matrices de confusion et le tableau III.5 nous observons que l'œsophagite a eu le taux de classification le plus élevé dans le cas du modèle VGG16 et VGG19. Tandis que la classe des polypes a eu le meilleur taux lors d'utilisation du modèle AlexNet (98,89%).

Comme le cas précédent, les trois modèles ont donné la meilleure précision dans le cas d'œsophagite en dépassant les 98%.

Pour le cas des polypes et colite ulcéreuse, la précision est inférieure à 95% en utilisant le modèle AlexNet, et comprise entre 96% et 97,7%.

La spécificité a dépassé les 98% dans tous les cas, sauf dans le cas du modèle AlexNet pour la classification de l'œsophagite et de la colite ulcéreuse.

Le modèle VGG19 a présenté les meilleures sensibilités dans les 3 cas pathologique. Pour comparer les métriques de chaque modèle nous allons présenter dans le tableau III.6

Le modèle	La moyenne			
	Taux de Classification	Précision	Sensibilité	Spécificité
Alexnet	96,59%	94 ,9%	94 ,9%	97,44%
VGG16	98,08%	97,1%	97,1%	98,56%
VGG19	98,52%	97,8%	97,1%	98,89%

Tableau III.6 : métriques moyenne des classes de la base augmentée et pré entraînée

D'après le tableau III.6, le modèle VGG19 a donné les meilleurs résultats en calculant les quatre paramètres d'évaluation. Suivie par le modèle VGG16 et enfin le modèle AlexNet. Nous constatons que le nombre de couches de convolution affecte la qualité de classification même dans de cas où les données d'apprentissage n'est pas suffisant.

III.2.2.5 Discussion

Dans le domaine de classification des images, le deep learning a connu des avancées significative avec grandes performances. Son avantage principal est sa capacité à extraire les informations pertinentes d'une manière automatique puis faire la classification. Il est capable de traiter un grand nombre de données d'une manière robuste. Ainsi que le deep learning est capable de faire ces tâches même si la qualité d'image est médiocre. Il calcule les paramètres avec un grand nombre de filtre. Ce qui permet de étudier l'image pixel par pixel. Dans notre

étude, nous avons utilisé les modèles du deep learning et nous avons eu des résultats satisfaisants.

III.2.2.5 .1 Comparaison entre les trois méthodes

Dans cette étude, nous avons commencé par l'utilisation d'un modèle de CNN non pré-entraîné, ce dernier n'a pas donné un taux de classification satisfaisant. Pour cela nous avons passé à l'utilisation des modèles pré-entraînés et à chaque fois nous avons changé le modèle en augmentant le nombre de couches de convolution dans chaque fois, nous avons remarqué que le taux de classification et la précision sont améliorés dans les modèles contenant un grand nombre de couches de convolution. Dont le modèle VGG19 a présenté les meilleurs paramètres. Dans ce cas, nous observons que l'utilisation des modèles pré-entraînés donne les meilleurs résultats par rapport aux modèles originaux. La dernière expérience consistait à étudier l'influence de nombre de données sur la classification par CNN. En comparant les résultats obtenus dans le cas des classes pathologique de la base augmentée avec les résultats des classes pathologiques de la base originale, nous avons trouvé que l'augmentation de données est une étape importante pour améliorer les performances du système. Car elle donne des résultats améliorés et évite le sous-apprentissage du système.

L'avantage des modèles pré-entraînés est l'amélioration de la précision du système. Ils permettent de créer un système robuste avec une possibilité d'erreur très faible. Ainsi que l'utilisation d'un grand nombre de données permet au système de mieux apprendre et donne une bonne généralisation c'est à dire augmente les performances et la robustesse du système. Enfin, l'utilisation des modèles avec un grand nombre de couches de convolution augmente le nombre de paramètres calculés et donc une classification plus précise.

III.2.2.5 .2 Comparaison avec l'état de l'art

Le tableau suivant représente la comparaison entre nos résultats obtenus et les méthodes existantes dans l'état de l'art en terme de taux de classification. Tous ces travaux sont testés sur la même base utilisée dans notre travail (Kvasir)

Travail réalisé par	méthode	Accuracy
zenebe Markos Lonseko[32]	Classification des pathologies par la méthode Attention-Guided Convolutional neural networks	92,48%

COGAN, Timothy [33]	MAPGI(modular adaptive preprocessing for gastrointestinal tract images) puis trois modèles de classification	Inception 98,45%
		Inception-Resnet 98,48%
		NASNet 97,35%
Şaban Öztürk[34]	Combinaison de CNN avec LSTM SVM, ARN	Le meilleur LSTM 97,90%
Quoc-Huy Trinh et al[37]	Dense-ResNet	92,63%
imran Iqbal et al [38]	Human Gastrointestinal tract Abnormalities Network (HGANet)	97,43%
Notre méthode	Les modèles du CNN pré entraînés AlexNet, VGG16, VGG19	AlexNet : 98,4%
		VGG16 : 99,82%
		VGG19 99,94%

Tableau III.7 : table comparative entre les méthodes de la littérature et nos méthodes

D'après le Tableau III.7 le taux de classification dans les travaux de littérature est compris entre 92% et 98%. Ces travaux ont utilisé la même base de données mais un nombre de classes différentes. Notre but était la détection des pathologies gastriques, pour cela nous avons utilisé seulement les 3 classes pathologiques.

En comparant nos résultats avec les résultats obtenus dans l'état de l'art, nos méthodes étaient les meilleures. Ces résultats sont améliorés lorsque nous utilisons les modèles pré entraînés (le transfert learning), l'augmentation de nombre de couches et le nombre de données d'apprentissage.

III.3 Interface graphique :

A la fin de ce memoire, nous avons réalisé une interface graphique. Cette dernière permet de detecter les 3 pathologies digestives d'une manière automatique. Ce qui facilite son utilisation par les experts.

Pour assurer la robustesse de systeme, nous avons choisi le modèle pré entraîné VGG19 pour l'implementer dans l'interface car il represente le modèle le plus precis

L'interface est réalisée d'apres la commende Guide sur Matlab. figure III.18




Figure III.18 : interface graphique

Après la réalisation de l'interface, nous avons fait un test pour assurer la fiabilité de notre système. Les résultats sont présentés dans les figures ci-dessous

- Cas d'oesophagite




Figure III.19 : detection de l'oesophagite

- Cas de polyes

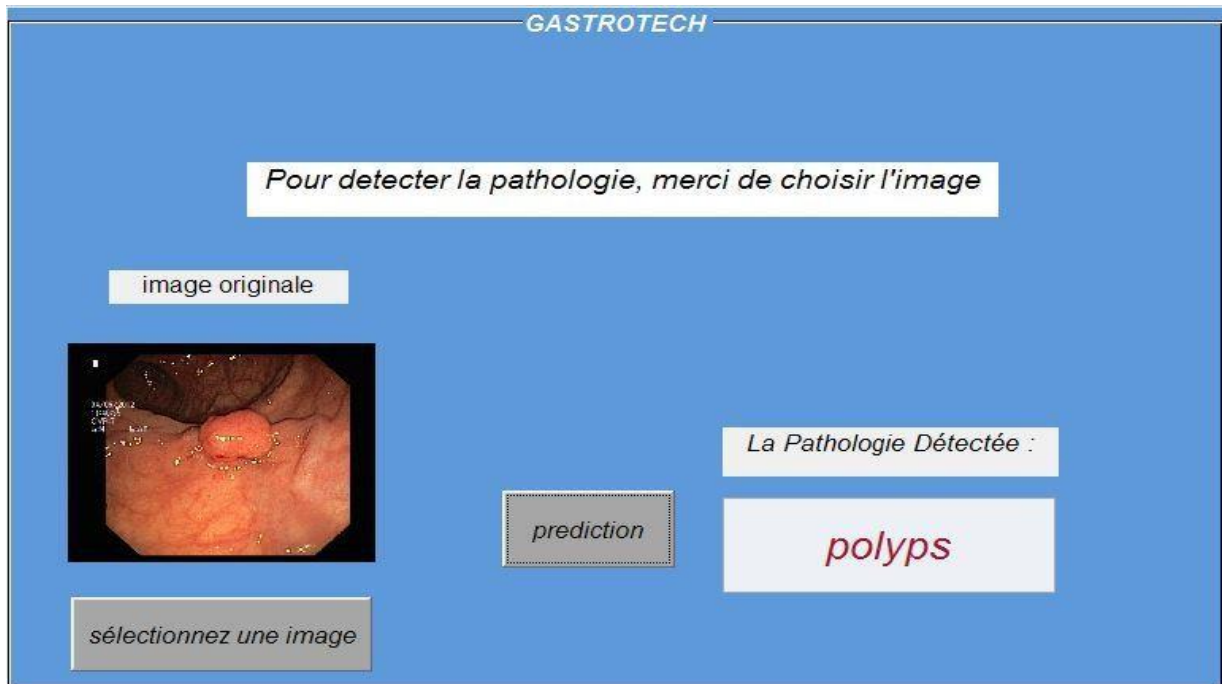


Figure III.20 : détection des polypes

- Colite ulcéreuse

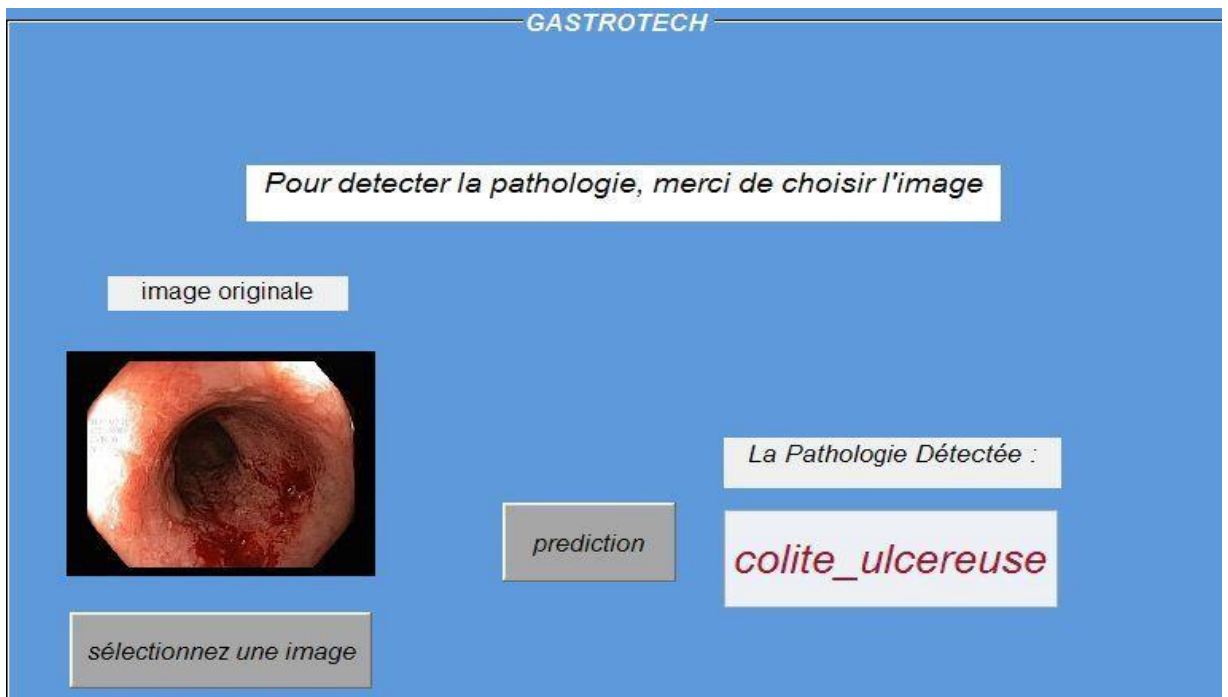


Figure III.21 : detection de la colite ulcéreuse

Conclusion :

Dans ce chapitre, nous avons présenté notre système proposé pour la classification des pathologies gastriques.

Nous avons tout d'abord décrit les outils utilisés dans le travail. Ensuite, nous avons passé à la présentation des modèles et architectures appliqués. Nous avons commencé par l'essai du modèle non pré-entraîné, dans ce cas nous avons trouvé que les résultats ne sont pas satisfaisants. Dans la deuxième phase, nous avons passé aux architectures pré-entraînées et à chaque fois nous appliquons un modèle plus profond pour évaluer l'impact de la profondeur d'un modèle dans l'amélioration du taux de classification. Le but de la dernière expérience est de montrer l'importance de l'étape d'augmentation de la base de données.

Ensuite, nous avons présenté les résultats des différentes méthodes utilisées dans le cadre de la détection des pathologies GI.

Puis, nous avons discuté et comparé entre nos méthodes proposées, puis avec les méthodes existantes dans l'état de l'art.

Nous avons conclu que le modèle pré-entraîné VGG19 donne le meilleur résultat avec un taux de classification de 99,94% dans le cas d'utilisation de la base de données augmentée.

Enfin, nous avons créé une interface graphique robuste grâce au modèle pré-entraîné VGG19. L'utilisation de cette interface facilite le diagnostic automatique des pathologies gastriques.

Conclusion générale

Le système digestif est responsable de la digestion et la transformation des aliments en nutriments utilisables et nécessaires pour la croissance et l'énergie de l'organisme. A cause de plusieurs facteurs, il peut être affecté par plusieurs pathologies. Ces maladies sont détectables par les différentes techniques d'imagerie médicale. L'endoscopie est l'une des meilleures méthodes pour l'exploration gastrique, car elle permet une visualisation en temps réel et sans l'utilisation des rayonnements nocifs. Le problème majeur de l'endoscopie est la qualité d'image qui est mauvaise à cause des régions sombres et les lésions qui contiennent une texture proche de la paroi examinée.

La solution est d'appliquer les méthodes de traitement d'image afin de régler ce problème. Avec le développement technologique et la naissance d'intelligence artificielle et ses algorithmes qui simulent l'intelligence humaine, il devient possible de l'employer dans le traitement d'image.

L'objectif de ce travail est d'employer les outils et les méthodes d'apprentissage profond : AlexNet, VGG16 et VGG19 pour détecter les pathologies gastriques d'une manière automatique. Les maladies détectées dans ce travail sont : les polypes, l'œsophagite et la colite ulcéreuse.

Pour un système plus performant et robuste, nous avons préféré d'utiliser les méthodes récentes et d'intégrer les algorithmes d'intelligence artificielle pour atteindre notre but.

Nous avons commencé le travail par la présentation des notions médicales nécessaires dans le premier chapitre, Puis dans le deuxième chapitre nous avons exposé les méthodes et les algorithmes qui seront utilisés dans notre travail. Dans le dernier chapitre, nous avons proposé un système automatique pour la classification multi-classes des pathologies gastriques. Pour cela, nous avons tout d'abord préparé nos données. Par la suite, nous avons étudié l'impact d'augmentation de base de données et le rôle des modèles pré entraînés dans l'amélioration des performances des systèmes de détection des pathologies ainsi que l'impact de la profondeur des CNN.

Nos méthodes ont été entraînées et testées sur la base de données publique Kavasir qui contient les images endoscopiques des différentes altérations.

En interprétant les résultats, nous avons conclu l'importance de nombre de données ainsi que le nombre de couches qui constituent le modèle dans un système de classification par deep learning.

A la fin nous allons dire que l'intelligence artificielle est un outil très important en traitement d'image. Elle offre des algorithmes compétents et puissants pour traiter une grande quantité de données d'une manière complètement automatique.

Les perspectives :

Ce projet présente un essai de classification des pathologies gastriques par les outils de deep learning. Ce travail peut être amélioré dans le futur en ajoutant d'autres tâches comme :

- L'utilisation des architectures plus puissantes et profondes.
- La collection d'une base de données locale (algérienne).
- La création d'un système d'aide au diagnostic médical capable de détecter automatiquement d'autres pathologies gastriques et l'intégrer dans un endoscope réel, le système va aider les experts en endoscopie lorsque la région est sombre et l'anomalie est illisible.
- Le traitement des séquences vidéos d'endoscopie.

Références bibliographiques

- [1] Le système digestif et son anatomie | Secondaire | Alloprof (<https://www.alloprof.qc.ca/fr/eleves/bv/sciences/le-systeme-digestif-et-son-anatomie-s1258>)
- [2] si salah hammoudi, anatomie appareil digestif, chap 1 cavité orale
- [3] Les glandes salivaires | Société canadienne du cancer (<https://cancer.ca/fr/cancer-information/cancer-types/salivary-gland/what-is-salivary-gland-cancer/the-salivary-glands-salivary>) 08/03/2023
- [4] MARIEB, E. Anatomie et physiologie humaine. REVUE DE L EDUCATION PHYSIQUE, 2000, vol. 40, no 1, p. 46-46.
- [5] Rappels d'anatomie et de physiologie – Le tube digestif – LABORATOIRE D'HISTOLOGIE et D'EMBRYOLOGIE (univ-nantes.fr) (<https://histologie.univ-nantes.fr/rappel-danatomie-et-de-physiologie/>)
- [6] Elise Magnin Estomac : anatomie, fonctionnement et pathologies (passeportsante.net) (<https://www.passeportsante.net/fr/parties-corps/Fiche.aspx?doc=estomac#:~:text=Seule%20la%20digestion%20des%20prot%C3%A9ines,des%20cellules%20de%20l'estomac.>)
- [7] absorption intestinale - LAROUSSE (https://www.larousse.fr/encyclopedie/medical/absorption_intestinale/10867#:~:text=L'absorption%20intestinale%20permet%20aux,chimiquement%20simples%2C%20faciles%20%C3%A0%20absorber) accédé le 12/03/2023
- [8] Rectum : définition, schéma de la fin du tube digestif (journaldesfemmes.fr) (<https://sante.journaldesfemmes.fr/fiches-anatomie-et-examens/2795967-rectum-definition-schema/>)
- [9] Anatomie et Physiologie Humaines. page 138
- [10] Quel est le rôle du foie dans la digestion ? (411answers.com) ([https://www.google.com/search?q=Quel+est+le+r%C3%B4le+du+foie+dans+la+digestion+%3F+\(411answers.com\)&oq=Quel+est+le+r%C3%B4le+du+foie+dans+la+digestion+%3F+\(411answers.com\)&aqs=edge..69i57.2557j0j4&sourceid=chrome&ie=UTF-8](https://www.google.com/search?q=Quel+est+le+r%C3%B4le+du+foie+dans+la+digestion+%3F+(411answers.com)&oq=Quel+est+le+r%C3%B4le+du+foie+dans+la+digestion+%3F+(411answers.com)&aqs=edge..69i57.2557j0j4&sourceid=chrome&ie=UTF-8))
- [11] Oesophagite : quels symptômes ? quels traitements ? | Santé Magazine (santemagazine.fr) (<https://www.santemagazine.fr/sante/fiche-maladie/oesophagite-894586>) 14/03/2023
- [12].Oesophagite - Quel est le traitement? - Fiches santé et conseils médicaux (lefigaro.fr) 14/03/2023

- [13] Reflux gastro-oesophagien (RGO) Causes, symptômes, traitement (doctissimo.fr) (06/02/2023)
- [14] L'œsophage de Barrett : symptômes, causes, diagnostics et traitements (msn.com)
- [15] Syndrome de Barrett : causes, symptômes, traitement - Ooreka 13/03/2023
- [16] Cancer de l'estomac : symptômes, prise de sang, quel pronostic ? (journaldesfemmes.fr) 28/03/2023
- [17] InfoCancer - ARCAGY - GINECO - Localisations - Appareil digestif - Cancer du côlon & du rectum - Maladie - Les polypes 26/04/2023
- [18] Polype : définition, causes, traitements | Elsan 26/04/2023
- [19] Simula Datasets - Kvasir 26/04/2023
- [20] Cancer du côlon : symptômes, causes, stades, comment savoir ? (journaldesfemmes.fr) 29/03/2023
- [21] Colite ulcéreuse - Société gastro-intestinale | www.mauxdeventre.org (badgut.org) 30/03/2023
- [22] Exploration : Endoscopie digestive haute | ameli.fr | Assuré 02/04/2023
- [23] Cécile Cauchy, ENDOSCOPE SOUPLE, Humatem, 2019, www.humatem.org/centre_de_ressource/Fiches-infos%20matériels
- [24] Cécile Cauchy, ENDOSCOPE RIGIDE, Humatem www.humatem.org/centre_de_ressource/Fiches-infos%20matériels
- [25] ASP (abdomen sans préparation) | Radiologie | Examens | Centre d'Imagerie de Coutances (imed-coutances.fr)(09/03/2023)
- [26] SCHMUTZ, G., LE PENNEC, V., PERDRIEL, B., et al. Méthodes d'imagerie de l'intestin grêle. EMC-Radiologie, 2005, vol. 2, no 1, p. 2-23.
- [27] Lavement baryté - Définition, indication, déroulement de l'examen - Doctissimo ACCEDE LE 09/03/2023
- [28] ROUSSET, J., BARC, R.-M., CONAN, C., et al. Aspects normaux et pathologiques du tube digestif en échographie. EMC-Radiologie, 2005, vol. 2, no 1, p. 24-42.
- [29] (PDF) Moyens D'exploration Du Tube Digestif (researchgate.net)(09/03/2023)
- [30] Rx et autres techniques d'imagerie du tube digestif - Troubles gastro-intestinaux - Édition professionnelle du Manuel MSD (msdmanuals.com) (12/03/2023)

- [31] ([Laparoscopie - Troubles gastro-intestinaux - Édition professionnelle du Manuel MSD \(msdmanuals.com\)](#)) 12/03/2023
- [32] LONSEKO, Zenebe Markos, ADJEI, Prince Ebenezer, DU, Wenju, et al. Gastrointestinal disease classification in endoscopic images using attention-guided convolutional neural networks. *Applied Sciences*, 2021, vol. 11, no 23, p. 11136.
- [33] COGAN, Timothy, COGAN, Maribeth, et TAMIL, Lakshman. MAPGI: Accurate identification of anatomical landmarks and diseased tissue in gastrointestinal tract using deep learning. *Computers in biology and medicine*, 2019, vol. 111, p. 103351.
- [34] ÖZTÜRK, Şaban et ÖZKAYA, Umut. Gastrointestinal tract classification using improved LSTM based CNN. *Multimedia Tools and Applications*, 2020, vol. 79, no 39-40, p. 28825-28840.
- [35] GAMMULLE, Harshala, DENMAN, Simon, SRIDHARAN, Sridha, et al. Two-stream deep feature modelling for automated video endoscopy data analysis. In : *Medical Image Computing and Computer Assisted Intervention–MICCAI 2020: 23rd International Conference, Lima, Peru, October 4–8, 2020, Proceedings, Part III* 23. Springer International Publishing, 2020. p. 742-751.
- [36] LEE, Sin-Ae, CHO, Hyun Chin, et CHO, Hyun-Chong. A novel approach for increased convolutional neural network performance in gastric-cancer classification using endoscopic images. *IEEE Access*, 2021, vol. 9, p. 51847-51854.
- [37] TRINH, Quoc-Huy, NGUYEN, Minh-Van, et al. Dense-Res Net for Endoscopic Image Classification. In : *CS & IT Conference Proceedings*. CS & IT Conference Proceedings, 2021.
- [38] IQBAL, Imran, WALAYAT, Khuram, KAKAR, Mohib Ullah, et al. Automated identification of human gastrointestinal tract abnormalities based on deep convolutional neural network with endoscopic images. *Intelligent Systems with Applications*, 2022, vol. 16, p. 200149.
- [39] WEN, Yan, ZHANG, Lei, MENG, Xiangli, et al. Rethinking the transfer learning for FCN based polyp segmentation in colonoscopy. *arXiv preprint arXiv:2211.02416*, 2022.
- [40] LONSEKO, Zenebe Markos, DU, Wenju, ADJEI, Prince Ebenezer, et al. Semi-Supervised Segmentation Framework for Gastrointestinal Lesion Diagnosis in Endoscopic Images. *Journal of Personalized Medicine*, 2023, vol. 13, no 1, p. 118.
- [41] LI, Sheng, ZHU, Beibei, GUO, Xinran, et al. Multi-scale high and low feature fusion attention network for intestinal image classification. *Signal, Image and Video Processing*, 2023, p. 1-10.
- [42] SAMUEL, Arthur L. Some studies in machine learning using the game of checkers. IBM

Journal of research and development, 1959, vol. 3, no 3, p. 210-229.

[43] CHASSAGNON, Guillaume, VAKALOLOPOU, Maria, PARAGIOS, Nikos, et al. Deep learning: definition and perspectives for thoracic imaging. *European radiology*, 2020, vol. 30, p. 2021-2030.

[44] Chima Igiri, Breast Cancer Prediction Using Artificial Neural Network, 2023, vol 8, No. 1 2022

[45] ZEMOURI, Ryad, DEVALLAND, Christine, VALMARY-DEGANO, Séverine, et al. Intelligence artificielle: quel avenir en anatomie pathologique?. In : *Annales de pathologie*. Elsevier Masson, 2019. p. 119-129.

[46] BENIKHLEF, Soumia, EL BATOUL, Bendimerad, et SETTOUTI, Nesma. Extraction des caractéristiques pour la classification de la maladie de Parkinson. 2013.

[47] AMIN, Khouani. Vers une reconnaissance intelligente des données biomédicale par apprentissage en profondeur. Thèse de doctorat. Université de Tlemcen-Abou Bekr Belkaid.

[48] Définition | Deep Learning - Apprentissage profond | Futura Tech (futura-sciences.com) 09/04/2023 (www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/)

[49] LECUN, Yann, BENGIO, Yoshua, et HINTON, Geoffrey. Deep learning. *nature*, 2015, vol. 521, no 7553, p. 436-444.

[50] Qu'est ce qu'un réseau de neurones convolutif (ou CNN) ? mise jour le 08/07/2022 (<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn>.) accédé le 12/04/2023

[51] Introduction aux réseaux neuronaux convolutifs (CNN) | 3 choses à savoir - MATLAB & Simulink (mathworks.com) (<http://fr.mathworks.com/discovery/convolutional-neural-network-matlab.html>) accédé le 19/04/2023.

[52] Convolutional Neural Network ou réseaux de neurones convolutifs : Tout ce qu'il y a à savoir (datascientest.com) (<https://datascientest.com/convolutional-neural-network>.) accédé le 12/04/2023

[53] Que signifie ReLU en matière d'intelligence artificielle ? - Actu IA" ActuIA 10 novembre 2018(<https://www.actuia.com/faq/que-signifie-relu-en-matiere-dintelligence-artificielle/#:~:text=ReLU%20est%20une%20fonction%20d,les%20r%C3%A9sultats%20n%C3%A9gatifs%20par%20z%C3%A9ro> .) accédé le 14/04/2023

[54] Découvrez les différentes couches d'un CNN - Classez et segmentez des données visuelles - OpenClassrooms <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn> .) 13/04/2023

[55] Henri Michel, Introduction au Transfer Learning" LE DATA SCIENCE (<https://ledatascientist.com/introduction-au-transfer-learning/#:~:text=Qu%27est-%20ce%20que%20le,un%20probl%C3%A8me%20diff%C3%A9rent%20mais%20connexe.%20|%20Le%20Data%20Scientistn> .) accédé le 16/04/2023

[56] KRIZHEVSKY, Alex. Advances in neural information processing systems. (No Title), 2012, p. 1097.

[57] SIMONYAN, Karen et ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.

[58] VGG : en quoi consiste ce modèle ? Daniel vous dit tout ! (datascientest.com) (<https://datascientest.com/quest-ce-que-le-modele-vgg>) accédé le 16/04/2023

[59] LEBOEUF, Paul-Antoine. Introduction à l'apprentissage automatique en pharmacométrie: concepts et applications. 2021.