

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche
Scientifique

Université d'Ibn Khaldoun –Tiaret–

Faculté des Sciences de la Matière

كلية علوم المادة

Département de Physique

قسم الفيزياء

Projet de fin d'étude:

Pour l'obtention du diplôme de

Master

Filière: Physique

Spécialité: Physique Médicale

Présenté par: Fedoul Arbia

Nait Hamoud Silina

Sujet:

***Apprentissage profond pour la segmentation automatique des lésions
tumorales dans les images Tomodensitométriques des poumons***

Soutenu le: 29 /06/2025, Devant le jury:

Mr.Belarbi El Habib	Président	Professeur	UNIV. Tiaret
Mr.Mahfoud Mohamed	Examineur	MCB	UNIV. Tiaret
Mr.Souidi Aabdelhakim	Concadrent	Docteur	UNIV. Tiaret
Mme.Mokkedem Fatima	Encadrente	MCB	UNIV. Tiaret
Mme.Latifa Houria	Invitée	Docteur	UNIV. Tiaret

Année universitaire 2024-2025

Remerciements

Nous tenons à exprimer nos plus sincères remerciements et notre profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce travail.

Nous adressons tout d'abord nos remerciement Mr.Souidi Abdelhakim, Notre concadrant, pour son accompagnement, sa disponibilité, ses précieux conseils et son encadrement tout au long de ce projet.

Nous remercions également Mme.Mokkedem Fatima, pour ses orientations professionnelles qui ont eu un impact positif sur notre parcours.

Nous tenons à remercier sincèrement les membres du jury le profisseur Belarbi El Habib, le docteur Mahfoud Mohamed, Docteur Latifa Houaria, pour le temps qu'ils ont consacré à l'évaluation de ce travail.

Nous exprimons aussi notre gratitude à l'ensemble des enseignants et du personnel administratif de département de physique, pour la qualité de la formation que nous avons reçue au cours de ces années.

Un grand merci à nos familles, pour leur soutien moral inconditionnel, leur patience et leur amour qui nous ont accompagnés tout au long de notre parcours.

Enfin, nous remercions nos amis et collègues de promotion pour leur présence, leur collaboration et les moments de partage qui ont rendu ce parcours plus humain et plus agréable.

إهداء:

إلى أمي...
يا جنّتي في الدنيا، يا وطنًا لا يغادرني، ويا أمانًا لا يُشبهه شيء. لولا دعاؤك في الغيب، وصبرك عليّ، ودعمك لي ما وصلتُ
إلى هذا الحلم. كل نجاح هو فيض من حبك، وكل إنجاز هو امتداد لقلبك الكبير.

إلى أخي الحبيب وسندي في درب الحياة...
من كنت له الأخت الصغيرة فصار لي ظهرًا لا ينكسر، وعزوة في أوقات الضعف. دمت لي رجلًا بقلب أبي، ورفيقًا لا يخذلني.

إلى أبي...
إلى من كان سندي في كل مراحل حياتي، إلى من علّمني أن الإرادة تصنع المستحيل، إلى من لم يبخل عليّ بدعمه، وتضحياته
إلى روح جدي الطاهرة...
رغم الغياب، ما زالت ملامحك تهمس لي بالصبر، وما زال دفء كلماتك يرافقني. سلامًا لروحك التي علّمتني أن القلوب الطيبة
لا تموت، بل تبقى نبراسًا ينير لنا الطريق.

إلى جدتي الغالية...
كنت لي الحزن حين ضاقت الدنيا، والحنان الذي لا يطلب شيئًا في المقابل. في صمتك دعاء، وفي ابتسامتك عمر جديد.

إلى خالاتي الحبيبات...
كنتن لي أكثر من أم، وأقرب من أخت. كنتن لقلبي ملاذًا، ولروحي دفئًا، ولأيامي سندًا جميلًا لا يُنسى.

إلى أخوالي الأعزاء...
منكم تعلّمت أن العائلة لا تُقدّر بثمن. لكم في القلب مكان لا يزول، وشكر لا يُقال بل يُحسّ.

إلى اختي...
زهرتي الصغيرة، و قطعة من قلبي... ابتسامتك الجميلة كانت كفيلة بأن تنسيني التعب

إلى شريكتي في المذاكرة، سيلينا...
رفيقة الجهد، ونصف هذا الإنجاز... في كل لحظة تعب كنا معًا، وفي كل فرحة نهاية نشاركها سويًا. شكرًا لروحك الجميلة التي
جعلت الطريق أقل وعورة.

إلى رفيقتي الدرب خولة و اية...
كنتُ محظوظة حين جمعتني الحياة بكما، لم تكونا مجرد صديقتين، بل الظّلين اللذين لا يفارقان قلبي، مهما تغيّرت الظروف.

إلى أسماء و منال ...
معكما اكتسبتُ أجمل الذكريات، وتعلّمتُ معنى الوفاء الحقيقي، كنتما لي ملاذًا حين ضاقت الدنيا، وابتسامةً حين غابت الفرحة.
شكرًا لقلبيكما، لصبركما، لحضوركما الدائم في كل تفصيلة من حياتي.

إلى صديقتي الحبيبات...
حياة، امينة، ريم، كوثر، نجمة، فاطمة، كنتن الزهر في طريقي، والضحكة في عزّ التعب، وجودكن لا يُقدّر بثمن، ولا يُختصر
بكلمات.

وأخيرًا... إلى نفسي،
يا من ظننت أن التعب سيهزمك، فنهضت من بين الرماد أقوى مما كنت... آمنت بالحلم رغم كل الشكوك، وسبرت رغم كل
العوائق، فهنيتُ لك هذا الإنجاز. أنا فخورة بك، فخورة جدًا

فدول عربية

Dédicace

À moi-même,

à celle qui est tombée, doutée, puis s'est relevée. Ce diplôme est la récompense d'un chemin de persévérance, de courage et de foi. Sois fière de toi.

À ma chère maman,

Ton amour et tes prières ont été ma lumière dans l'obscurité. Ce succès t'appartient.

À mon père,

Ta présence discrète mais forte m'a portée. Merci d'être ce modèle de sagesse et de patience.

À ma binôme, Nadjet,

Ta présence fut lumière dans les moments sombres et force dans les instants de fatigue.

À Mélissa, ma petite sœur adorée, et à mes frères, Chems-Eddine et Abdelnour,

Merci d'avoir rempli mes journées de rires sincères, d'énergie contagieuse et d'un amour fraternel inestimable..

À ma tante Nawal,

Deuxième mère et pilier affectif, ta tendresse et ton soutien m'ont été inestimables. Je te porte dans mon cœur.

À mes amis chers, et tout particulièrement à Aïcha et Amel,

Merci à vous tous pour votre présence; votre soutien et vos sourires tout au long de ce parcours.

À ma famille chère, et tout particulièrement à mon oncle bien-aimé Nabil, votre amour inconditionnel m'a portée jusqu'ici. Ce diplôme est aussi le vôtre.

Nait Hamoud Silina

Sommaire

إهداء:	3
Dédicace	4
Liste des figures :	9
Liste des tableaux :	10
1. Introduction Générale :	12
2. Problématique:	14
I. Chapitre I: Contexte médicale	15
1. Anatomie des poumons	16
1.1. Anatomie descriptive:	16
1.1.1. Le poumon droit:	17
1.1.2. Le poumon gauche:	17
1.1.3. Trachée-arbre bronchique:	18
1.1.4. Les artères pulmonaires:	19
1.1.5. Les veines pulmonaires:	20
1.1.6. Les artères bronchiques:	21
1.1.7. Lymphatique pulmonaire:	22
1.1.8. L'innervation pulmonaire:	22
2. Cancers broncho-pulmonaires:	23
2.1. Les Cancers bronchiques non à petites cellules (CBNPC) :	23
2.1.1. Adénocarcinome:	24
2.1.1.1. HAA (Hyperplasie Adénomateuse Atypique):	24
2.1.1.2. AIS (Adénocarcinome In Situ):	25
2.1.1.3. AIM (l'adénocarcinome invasif minimal):	26
2.1.2 CARCINOME SQUAMEUX DU POUMON:	27

2.1.3 CARCINOME PULMONAIRE À GRANDES CELLULES	28
2.2 Les cancers bronchiques à petites cellules (CBPC) :	29
2.3 Classification TNM:	30
3. Détection des lésions tumorales par Imagerie Tomodensitométrie (TDM)	32
3.1. Principe de la TDM:	32
3.1.1. Principe de formation de l'image :	32
3.1.1.1. Atténuation:	33
3.1.1.2. Échelle Hounsfield :	33
3.1.1.3. Projections:	34
3.1.1.4. Rétroprojection:	34
3.1.1.5. Passage de la matrice à l'image :	34
3.1.2. Composants et technologie du scanner TDM	35
3.1.2.1. Générateur de tube à rayons X :	35
3.1.2.2. Tube:	35
2.1.1.1. Filtration et collimation:	36
2.1.1.1.1. Filtration des rayons X:	36
3.1.2.2.1. Collimations primaire et secondaire:	36
3.1.2.2.2. Collimateurs de champ:	37
3.1.3. Système de detection:	37
3.1.3.1. Détecteur à gaz:	37
3.1.3.2. Détecteurs solides:	38
3.1.4. Les Risques:	38
3.1.5. Rôle de la TDM:	38
3.2. Tomodensitométrie du Thorax:	38

3.2.1. TDM Thoracique à Visée Diagnostique	39
3.2.1.1. Détection des Anomalies	39
3.2.1.2. Modèles de Maladie	39
3.2.1.3. Validation des Diagnostics	40
3.2.2. TDM Thoracique à Visée thérapeutique	40
3.2.2.1. Guidage des Procédures Interventionnelles	40
3.2.2.1.1. Biopsies percutanées :	40
3.2.2.1.2. Drainage pleural :	40
3.2.2.1.3. Ablations tumorales :	40
3.2.2.1.4. Planification et Suivi des Traitements	41
• La planification de la radiothérapie	41
• Le suivi de la chimiothérapie ou de l'immunothérapie	41
• Le contrôle post-opératoire	41
4. Radiothérapie externe:	41
4.1. Enjeux de la radiothérapie guidée par l'imagerie TDM	41
4.1.1. Précision du ciblage:	41
4.1.2. Marge de sécurité:	41
4.1.3. Optimisation des traitements:	41
II. Chapitre II : État de l'art	42
1. Les méthodes de segmentation des volumes tumoraux broncho-pulmonaires : Revue des approches proposées pour la détection automatique des contours des volumes cibles tumoraux. .	43
1.1. Introduction:	43
1.2. L'intelligence artificielle:	43
1.3. L'intelligence artificielle:	44

1.4. Méthodes de segmentation basées sur l'apprentissage profond :	44
1.5. Conclusion :	48
III. Chapitre III: Matériel et méthodologie	49
1. Introduction:	50
2. Base de données	50
3. Notions de l'apprentissage profond	53
3.1. Perceptron multi-couche	53
3.1.1. Nourone formel:	53
3.1.1.1. Perceptron multicouche:	54
3.1.1.2. Optimisation de l'apprentissage du MLP par des algorithmes :	56
3.2. Réseaux de Neurones convolutifs	57
3.2.1. Couches de convolution	57
3.2.2. Couches de pooling :	58
3.2.3. Couches entièrement connectées :	59
3.3. Réseau de neurones profond	59
3.3.1. Structure d'un DNN:	59
3.3.2. Fonction d'activation:	60
3.3.3. Fonction de perte (loss):	61
3.3.4. Rétropropagation et gradient:	61
3.3.5. Mise à jour des parametres :	62
3.4. Architecture U-Net :	62
3.5. U-Net avec mécanisme d'attention pour segmentation des images biomédicales:	63
4. Métriques d'évaluations	65
4.1. Précision:	65
4.2. Sensibilité:	65

4.3. Spécificité:	65
4.4. Le coefficient de Dice	66
5. Conclusion:	67
IV. Chapitre 04 : Résultats et discussions	68
1. Introduction :	69
2. Résultats	69
1. Discussion :	72
2. Conclusion :	74
5. Conclusion Générale:	75
Références:	76

Liste des figures :

FigureI-1 : La position des poumons	16
Figure I-2 : Situation des segments à la surface des poumons	17
Figure I-3 : Vue antérieure de la trachée : morphologie externe.	19
Figure I-4 :A : Schéma des relations normales entre l'arbre trachéobronchique et l'artère pulmonaire, B : Bronche en pont avec artère pulmonaire gauche en écharpe(SLPA), C : Bronche en pont sans artère pulmonaire gauche en écharpe(SLPA).	20
Figure I-5 : Artères pulmonaires et veines pulmonaires	21
Figure I-6 : Schéma d'ensemble des lymphatiques.	22
Figure I-7 : Innervation pulmonaire.	23
Figure I-8 : Faible opacité du verre de sol dans le segment apicale gauche du lobe inférieur.	
Notez qu'il n'y a pas de distorsion des vaisseaux ou du composant solide	25
Figure I-9 : Il s'agit de la TDM initiale montrant un nodule de 5 mm avec opacification du verre circonscrit	26

Figure I-10 : L'opacité focale en verre poli dans le segment supérieur du lobe inférieur droit a augmenté, mesurant 12 mm de diamètre. Les nodules pulmonaires restants sont inchangés. Les poumons ne sont pas remarquables. Aucune lymphadénopathie médiastinale	27
Figure I-11 : Tomographie (TDM) par ordinateur.	28
Figure I-12 : Carcinome à grandes cellules de haute qualité.	29
Figure I-13: Cancer du poumon à petites cellules avec de multiple nodules pulmonaires et des métastases nodulaires médiastinales étendues.	30
Figure I-14: L'appareil du scanner.	32
Figure I-15: tubes et détecteurs qui tournent autour du patient.	33
Figure I-16: Principe de la projection.	34
Figure I -17: Collimation primaire et secondaire.	37
Figure I I I -1:Image de TDM d'un cas normal de labase de données DMC	51
Figure I I I -2: Image de TDM d'un cas pathologique de labase de données DMC	51
Figure I I I -3: Conception de neurones biologiques et artificiels.	53
Figure I I I -4: Exemple d'un MLP ayant deux couches cachées	56
Figure I I I -5: schéma d'une convolution avec un noyau de taille 3*3 et un pas de 2	57
Figure I I I -6: Fonctionnement d'un neurone artificiel avec activation ReLU	62
Figure I I I -7: Architecture UNET avec un block d attention	64
figure IV-1 :Les résultats de segmentation en comparaison avec le masque réel	70
FigureIV-2 : Courbes de la perte d'entraînement et de la perte de validation	71

Liste des tableaux :

Tableau I-1 : Nom des segments (et de leurs bronches)	18
Tableau I-2: Classification TNM des cancers pulmonaires : Tumeur primaire, Ganglions lymphatiques et Métastases	31

TableauII-1: Résumé comparatif des méthodes de segmentation pulmonaire basées sur l'apprentissage profond	47
TableauIV-1: Hyperparamètres	69
TableauIV-2: caractéristiques de l'ordinateur utiliser	69
TableauIV-3: Notre résultats de chaque modèle	71
TableauIV-5: comparaison résultats que nous avons obtenus avec d'autres travaux ultérieurs sur la même base de données	71

1. Introduction Générale :

Le cancer du poumon constitue un enjeu majeur de santé publique à l'échelle mondiale, se classant parmi les principales causes de mortalité liée au cancer chez les deux sexes[1]. Ce taux élevé de mortalité s'explique en grande partie par un diagnostic souvent tardif, intervenant à un stade avancé de la pathologie, où les options thérapeutiques deviennent limitées et les chances de survie réduites [2] . Dans ce contexte, le dépistage précoce des lésions tumorales représente un levier essentiel pour améliorer la prise en charge des patients et optimiser le pronostic clinique.

Parmi les outils diagnostiques disponibles, l'imagerie médicale, et plus particulièrement la tomodensitométrie (TDM), occupe une place centrale. Cette modalité d'imagerie permet une exploration détaillée de l'anatomie pulmonaire et offre une visualisation précise des structures pathologiques, contribuant ainsi de manière déterminante à la détection et à la caractérisation des tumeurs pulmonaires[3, 4].

Malgré les avancées significatives en imagerie médicale, l'analyse et l'interprétation des images tomodensitométriques demeurent fortement dépendantes de l'expertise des cliniciens. En particulier, la segmentation manuelle des lésions tumorales, consistant à délimiter avec précision les contours des structures pathologiques, reste une tâche laborieuse et chronophage. Cette méthode est en outre sujette à une variabilité inter- et intra-observateur importante, susceptible de compromettre la reproductibilité et la fiabilité des résultats[5, 6]. Ces incertitudes peuvent avoir des répercussions cliniques notables, notamment dans le cadre de la planification en radiothérapie, où une segmentation imprécise peut entraîner soit une irradiation insuffisante de la tumeur, soit une atteinte non désirée des tissus sains environnants[7].

Face aux limites inhérentes aux méthodes manuelles de segmentation, le développement d'approches automatisées, fiables et rapides s'impose comme une alternative incontournable. Dans ce cadre, les avancées récentes en intelligence artificielle (IA), et plus particulièrement en apprentissage profond, ont suscité un intérêt croissant dans le domaine de l'analyse d'images médicales. Les réseaux de neurones profonds sont capables d'extraire de manière automatique des représentations complexes à partir de grandes quantités de données, ce qui leur confère une efficacité remarquable dans les tâches de segmentation d'images médicales[3, 8].

Parmi les architectures les plus éprouvées, le modèle U-Net, introduit initialement pour la segmentation d'images biomédicales en deux dimensions, s'est imposé comme une référence grâce à sa capacité à combiner des informations à la fois globales et locales via une architecture en forme d'encodeur-décodeur symétrique[9]. Plusieurs variantes du U-Net ont par la suite été proposées, intégrant notamment des mécanismes d'attention destinés à renforcer la capacité du réseau à se concentrer sur les régions les plus pertinentes de l'image, et à améliorer la précision de la délimitation des structures anatomopathologiques[10, 11].

Dans ce travail, nous proposons de concevoir un modèle de segmentation automatique des lésions tumorales pulmonaires à partir d'images tomodensitométriques, en nous appuyant sur une architecture de type U-Net enrichie par un mécanisme d'attention. Ce choix est motivé par les performances avérées d'U-Net dans les tâches de segmentation biomédicale[9], ainsi que par l'intérêt croissant des mécanismes d'attention, qui permettent d'améliorer la précision des prédictions en focalisant l'apprentissage sur les régions d'intérêt[10]. Le modèle développé sera évalué à l'aide de métriques quantitatives standards, notamment la sensibilité, la spécificité et le coefficient de Dice, qui sont largement utilisés pour mesurer la qualité de la segmentation par rapport à des annotations de référence[5]. Par ailleurs, une analyse comparative avec des architectures de référence permettra de mettre en évidence les apports spécifiques du mécanisme d'attention sur la performance globale du système proposé.

Ainsi, le mémoire est organisé de la manière suivante : le premier chapitre expose le contexte médical, en mettant l'accent sur l'anatomie des poumons, les différentes sortes de cancers broncho-pulmonaires et l'importance de la TDM dans leur identification. Le deuxième chapitre présente un aperçu des diverses méthodes de segmentation automatique. Le troisième chapitre présente la base de données employée, les principes de l'apprentissage profond et l'architecture de segmentation choisie. Finalement, le quatrième chapitre se focalise sur la présentation des résultats obtenus et leur analyse, avant de conclure sur les perspectives de ce travail.

2. Problématique:

Le cancer du poumon figure parmi les formes de cancer les plus mortelles à l'échelle mondiale. Pour optimiser le diagnostic et le soin, il est crucial d'identifier et de situer avec exactitude les lésions tumorales dans les images médicales, en particulier celles issues de la tomodensitométrie (TDM). Cependant, le segmentage manuel de ces images est laborieux, complexe et sujet à des erreurs humaines.

Face à ces limites, une question se pose :


Comment utiliser l'apprentissage profond pour automatiser la segmentation des lésions tumorales pulmonaires dans les images TDM, de manière rapide, précise et fiable ?

I. Chapitre I: Contexte médicale

1. Anatomie des poumons

1.1. Anatomie descriptive:

Les poumons sont les principaux organes de la respiration. Ils sont situés dans la cavité thoracique, où ils sont protégés par les côtes et enveloppés par la plèvre. Ils sont séparés par le médiastin et présentent une asymétrie morphologique : le poumon droit, plus volumineux, pèse environ 650 g, tandis que le poumon gauche, légèrement plus petit en raison de la présence du cœur, pèse environ 550 g (Figure I-1). Leur capacité pulmonaire moyenne est d'environ 5 litres. Chaque poumon est subdivisé en lobes (trois pour le poumon droit, deux pour le gauche) et en segments broncho-pulmonaires, facilitant ainsi le repérage des pathologies à l'aide des techniques d'imagerie médicale [12, 13].



FigureI-1 : La position des poumons[14]

1.1.1. Le poumon droit:

Le poumon droit est légèrement plus grand que le poumon gauche et est composé de trois lobes. Ces lobes sont séparés par deux scissures, l'une semi-horizontales et l'autre oblique. Chaque lobe divisé en segments. La figure (Figure I-2) illustre la situation des segments à la surface des poumons :

Le lobe supérieur est divisé en trois segments, apical, dorsal et ventral. Le lobe moyen est divisé en deux segments, interne (médial) et externe (latéral). Le lobe inférieur est divisé en cinq segments, apical (nelson), terminobasal postérieur, latérobasal, ventrobasal (antérieur), paracardiaque (interne) [12, 14].

1.1.2. Le poumon gauche:

Le poumon gauche est plus petit que le poumon droit en raison de la présence du cœur du côté gauche. Il est composé de deux lobes, séparés par une scissure oblique. Le lobe supérieur peut être divisé en deux régions en raison de la disposition des bronches et du drainage veineux, culmen et lingula. Chacune de ces deux régions est divisée en segments. Le culmen est constitué de trois segments, apical, dorsal, ventral. La lingula est composée de deux segments, supérieur, inférieur. Lobe inférieur est divisé en cinq segments, apical (nelson), paracardiaque, ventrobasal, latérobasal, terminobasal.[12, 14]




Figure I-2 : Situation des segments à la surface des poumons (Tableau-1). (A) Représentation de profil droit, (B) Représentation de face, (C) Représentation du profil gauche (B). [12].

Poumon droit		Numéro	Poumon Gauche	
Nom de segment			Nom de segment	
Lobe supérieur	Apical	1	Apical	Culmen
	Antérieur (ventral)	2	Antérieur (ventral)	
	Postérieur (dorsal)	3	Postérieur (dorsal)	
Lobe moyen	Latéral (externe)	4	Supérieur	Lingula
	Médial (interne)	5	Inférieur	
Lobe inférieur	Apical (Nelson)	6	Apical (Nelson)	Lobe inférieur
	Médial (paracardiaque)	7	Médial (paracardiaque)	
	Antérieur (ventrobasal)	8	Antérieur (ventrobasal)	
	Latéral (latérobasal)	9	Latéral (latérobasal)	
	Postérieur (terminobasal)	10	Postérieur (terminobasal)	

Tableau I-1. Nom des segments (et de leurs bronches) [12]

1.1.3. Trachée-arbre bronchique:

La trachée est un conduit fibro-musculo-cartilagineux reliant le larynx aux bronches principales. Sa structure rigide empêche son effondrement lors des variations de pression respiratoire, tandis que le muscle trachéal ajuste son diamètre. Son épithélium cilié joue un rôle clé dans l'évacuation des sécrétions. Elle se prolonge jusqu'au hile des poumons, où les bronches principales pénètrent et assurent la distribution de l'air.

À son extrémité inférieure, la trachée se divise en deux bronches principales au niveau de la carène :

Bronche droite : Plus courte (20-25 mm), plus large (15-16 mm) et plus verticale (~25°), facilitant l'entrée des corps étrangers.

Bronche gauche : Plus longue (40-45 mm), plus étroite (10-11 mm) et plus oblique (~45°).

Les bronches principales se ramifient en bronches lobaires (trois à droite, deux à gauche), puis en bronches segmentaires, avant d'aboutir aux bronchioles qui conduisent l'air jusqu'aux alvéoles pour l'échange gazeux. Cette structure en arbre garantit une ventilation efficace des poumons.[15]




Figure I-3 : Vue antérieure de la trachée : morphologie externe. 1. Os hyoïde ; 2. Cartilage thyroïde ; 3. Cartilage cricoïde ; 4. Bronche principale droite ; 5. Trachée cervicale ; 6. Trachée thoracique; 7. Carène; 8. Bronche principale gauche.[15]

1.1.4. Les artères pulmonaires:

Ils naissent du tronc pulmonaire, issu du ventricule droit, et suivent le trajet des bronches à partir du hile pulmonaire. Leur division est généralement dichotomique mais présente des variations anatomiques. L'artère pulmonaire droite (22 mm de long) suit un trajet horizontal et irrigue les lobes pulmonaires droits via plusieurs branches, dont l'artère médiastinale, dorsale et ventrale scissurale pour le lobe supérieur, ainsi que l'artère lobaire moyenne et l'artère de Nelson pour les lobes moyen et inférieur. L'artère pulmonaire gauche, prolongeant directement le tronc pulmonaire, contourne la bronche souche gauche avant d'atteindre la bronche lobaire inférieure. Elle irrigue le lobe supérieur gauche par des branches médiastinales et scissurales, et le lobe inférieur gauche via l'artère du segment de Nelson, les artères de la pyramide basale et le tronc ventroparacardiaque. Cette vascularisation complexe assure l'apport sanguin aux lobules pulmonaires pour les échanges gazeux.[12]




Figure I-4 :A : Schéma des relations normales entre l'arbre trachéobronchique et l'artère pulmonaire, B : Bronche en pont avec artère pulmonaire gauche en écharpe(SLPA), C : Bronche en pont sans artère pulmonaire gauche en écharpe(SLPA).[16]

1.1.5. Les veines pulmonaires:

Les veines pulmonaires transportent le sang oxygéné des poumons vers l'oreillette gauche du cœur. Situées en périphérie des poumons, elles commencent par de petites veinules collectant le sang des alvéoles, qui se rejoignent en veines périlobulaires, puis en vaisseaux plus larges répartis entre les subdivisions pulmonaires, les segments et sous la plèvre. Contrairement aux autres veines du corps, elles ne possèdent pas de valves. Les veines pulmonaires supérieures (droite et gauche) drainent le sang des lobes supérieurs, avec des racines collectant le sang des différentes parties du poumon. Les veines pulmonaires inférieures, plus postérieures, assurent le retour veineux des lobes inférieurs, notamment via les veines interbasales et basales. Chaque veine pulmonaire atteint finalement le cœur, parfois séparément ou en fusionnant exceptionnellement en un seul vaisseau.[12]




Figure I-5 : Artères pulmonaires et veines pulmonaires : reconstruction scanographique. A, B : Vue de face avant (A) et après (B) ablation de l'aorte ascendante. C, D : Vue de trois quarts avant (C) et après (D) ablation de l'aorte ascendante, visant à « dérouler » l'artère pulmonaire gauche. E : Vue postérieure de l'oreillette gauche et des veines pulmonaires .[12]

1.1.6. Les artères bronchiques:

Ils assurent l'oxygénation des poumons et des bronches, un rôle crucial notamment en cas de transplantation pulmonaire. Elles proviennent principalement de l'aorte descendante (entre T5 et T6) et se présentent sous différentes formes : une artère droite et une gauche séparées, un tronc commun, ou un tronc broncho-intercostal droit, la configuration la plus fréquente. Leur nombre varie de 1 à 4 par individu, bien qu'une seule artère puisse exceptionnellement irriguer les deux poumons. En présence de maladies pulmonaires, elles peuvent contribuer à une néovascularisation impliquant d'autres artères thoraciques pour compenser un besoin accru en oxygène. Elles irriguent également la trachée, l'œsophage, le péricarde, la plèvre et l'oreillette gauche, avec parfois des anastomoses avec les artères coronaires.[12]

1.1.7. Lymphatique pulmonaire:

Le système lymphatique pulmonaire est responsable du drainage des liquides des tissus pulmonaires. La lymphe circule via les bronches ou les veines pulmonaires pour atteindre le médiastin et rejoindre la circulation sanguine. Son trajet varie : une partie atteint directement les ganglions lymphatiques médiastinaux, tandis qu'une autre suit des chemins différents entre les lobes pulmonaires. Cette organisation influence la propagation du cancer du poumon, mais les classifications médicales comme le TNM ne prennent pas toujours en compte la complexité des connexions ganglionnaires. [12]




Figure I-6 : Schéma d'ensemble des lymphatiques. Abouchement des lymphatiques aux confluents veineux de Pirogoff (flèches) et à la crosse du canal thoracique (têtes de flèches) et anastomoses des chaînes médiastinales au canal thoracique dans le médiastin.[12]

1.1.8. L'innervation pulmonaire:

L'innervation pulmonaire provient du système nerveux autonome, comprenant des fibres parasympathiques (nerf vague) et sympathiques (ganglions cervicaux et thoraciques). Ces fibres forment des plexus nerveux autour des artères et des bronches, divisés en plexus extra-cartilagineux et sous-cartilagineux. Les fibres efférentes sympathiques naissent des ganglions latérovértébraux, tandis que les fibres efférentes parasympathiques proviennent des ganglions situés dans la paroi des bronches. Les fibres afférentes n'atteignent le système nerveux central que par l'intermédiaire du nerf vague[12].




Figure I-7 : Innervation pulmonaire.[14]

2. Cancers broncho-pulmonaires:

2.1. Les Cancers bronchiques non à petites cellules (CBNPC) :

Les cancers pulmonaires non à petites cellules (CBNPC) constituent 85 % des néoplasies pulmonaires. Les CBNPC comprennent divers types de cancers, notamment les adénocarcinomes (CCAP), les carcinomes à cellules squameuses (CCSP) et les cancers à grandes cellules. Parmi ces derniers, les CCAP et les CCSP représentent les plus importants sous-groupes des CBNPC. Les CCAP et les CCSP se distinguent clairement sur le plan transcriptomique, tout comme en ce qui concerne les réseaux de régulation cellulaire. Les CCAP présentent des caractéristiques génétiques uniques et des profils pronostiques différents par rapport aux CCSP.[17]

2.1.1. Adénocarcinome:

L'adénocarcinome est désormais le type de cancer du poumon le plus répandu, constituant environ 50 % des cas diagnostiqués de cancer du poumon. Sa prévalence est en hausse, en partie en raison de modifications des comportements de tabagisme et de l'augmentation de l'exposition des cellules des voies respiratoires périphériques à des substances cancérogènes. Ce type de cancer apparaît à partir de lésions pré-invasives, telles que l'hyperplasie adénomateuse atypique (HAA), qui peut progresser vers l'adénocarcinome in situ (AIS), l'adénocarcinome invasif minimal (AIM) et finalement un adénocarcinome invasif. Cette évolution suit un continuum reconnaissable par des traits radiologiques, en particulier la présence de nodules en verre dépoli. [18]

2.1.1.1. HAA (Hyperplasie Adénomateuse Atypique):

HAA est identifié comme une lésion susceptible de donner naissance à l'adénocarcinome pulmonaire et est généralement indétectable par les méthodes d'imagerie. Le HAA est généralement identifiée lors de l'examen de prélèvements chirurgicaux montrant une tumeur maligne. LeHAA représente une lésion. Sur la tomographie (TDM), le AAH, lorsqu'elle est visible, apparaît comme un petit nodule en verre dépoli c'est GGN (Ground-Glass Nodule), sa petite taille, et l'absence de progression rapide orientent vers une prise en charge conservatrice avec surveillance régulière.

La fréquence de le HAA est élevée dans les poumons ressectés chirurgicalement tissus qui abritent le cancer du poumon, en particulier l'adénocarcinome pulmonaire. Parmi les adénocarcinomes HAA coexiste fréquemment avec le SIA. Ce risque plus élevé HAA dans les tissus pulmonaires hébergeant un adénocarcinome peut s'expliquer par la cancéroïsation du champ ce qui suggère que le tissu pulmonaire normal est à risque développer un adénocarcinome parce qu'il possède des caractéristiques génétiques qui rendent le tissu vulnérable le développement de le HAA, qui est souvent suivi d'un adénocarcinome invasif,HAA est une petite lésion (généralement inférieure à 0,5 cm) qui se produit habituellement dans la périphérie pulmonaire, surtout près de la plèvre. Le HAA est souvent indétectable par voie macroscopique mais peut être souvent identifié au microscope.[18]




Figure I- 8 : Faible opacité du verre de sol dans le segment apical gauche du lobe inférieur. Notez qu'il n'y a pas de distorsion des vaisseaux ou du composant solide, A : coupe axiale, B : coupe coronale

2.1.1.2. AIS (Adénocarcinome In Situ):

L'AIS est un petit adénocarcinome (défini comme mesurant au plus 3 cm de diamètre) qui se trouve souvent en périphérie pulmonaire, à proximité de la plèvre. Dans la classification de Noguchi.[19]

Les lésions AIS, qui se réfèrent à l'adénocarcinome de type A ou de type B de Noguchi, sont localisées et progressent lentement. Quand les lésions d'AIS sont présentes, la survie sans maladie atteint presque 100 %. Les tumeurs AIS peuvent être classées en variantes mucineuses et non mucineuses; néanmoins, la variante mucineuse est très peu fréquente. . L'AIS est habituellement identifié par coïncidence, Sur la TDM, l'AIS apparaît comme un petit GGN sans composant solide, semblable à le HAA. En cas d'AIS mucineux, les lésions montrent très rarement un nodule solide ou en partie solide. Macroscopiquement, AIS apparaît généralement comme une Nodule mal délimité avec une surface coupée de couleur bronzée ou pâle. Microscopiquement, l'AIS apparaît comme croissance lépidique pure des cellules tumorales le long de structures alvéolaires préexistantes et manque lymphatique, invasion vasculaire, stromale ou pleurale [18].




Figure I-9 : Il s'agit de la TDM initiale montrant un nodule de 5 mm avec opacification du verre circonscrit, les dimensions totales sont d'environ. 18mm x 15mm dans le lobe supérieur gauche.

2.1.1.3. AIM (l'adénocarcinome invasif minimal):

L'AIM a été placé en tant que nouvelle entité tumorale entre l'AIS et l'adénocarcinome lépidique dans la Classification de l'OMS de 2015. L'instauration du AIM est cohérente d'un point de vue clinique pathologique. Le AIM est un adénocarcinome de taille réduite (d'un diamètre maximum de 3 cm) dont la plupart des cas présentent un aspect lipidique et une architecture invasive ne dépassant pas 5 mm (figure 11). L'AIM est généralement non mucineux, mais il peut être mucineux dans de rares cas. Tout comme pour l'AIS, l'AIM est généralement identifié par hasard lors d'une TDM réalisée pour d'autres motifs médicaux. Sur une TDM, l'AIM se présente souvent sous la forme d'un GGN dans la périphérie pulmonaire avec une partie solide de moins de 5 mm. La lésion invasive requiert une distinction entre l'effondrement alvéolaire, la fibrose et les muqueuses qui peuvent aussi engendrer une apparence solide sur le scanner. Considérant que Le diagnostic différentiel entre AIM et AIS mucineux est problématique sur les CT, les nodules multiples et propagation du nodule au parenchyme pulmonaire adjacent avec une frontière indistincte soutenir le diagnostic de AIS mucineux. Cliniquement, l'AIM ne devrait pas réapparaître s'il est complètement éliminé (figureI-10) .[18]




Figure I-10 : L'opacité focale en verre poli dans le segment supérieur du lobe inférieur droit a augmenté, mesurant 12 mm de diamètre. Les nodules pulmonaires restants sont inchangés. Les poumons ne sont pas remarquables. Aucune lymphadénopathie médiastinale, A : coupe coronale, B : coupe sagittale, C: coupe axial, coupe axiale avec zoom

2.1.2 CARCINOME SQUAMEUX DU POUMON:

Le carcinome épidermoïde (CCSP) des poumons est lié au tabagisme dans son apparition.[19] Bien que le nombre de patients souffrant de CCSP ait diminué ces dernières années en raison de la réduction de la proportion de fumeurs, cela représente encore environ 20 à 30 % de tous les cancers pulmonaires. [19]

À la différence de le CCAP, le CCSP émane de cellules qui s'étendent dans les voies respiratoires des poumons. Le CCSP est divisé en sous-types kératinisant, non kératinisant et basaloïde. Les CCSP sont associées à un passé de tabagisme et se rencontrent souvent dans les bronches principales, au niveau des zones centrales des poumons. Aucune différence significative n'a été observée dans les sous-types CCSP concernant les caractéristiques clinicopathologiques, la localisation, l'atteinte pleurale, l'invasion lymphovasculaire, l'âge, les lésions moléculaires (comme récepteur du facteur de croissance épidermique) ou le pronostic.[20]




Figure I-11 : Tomographie (TDM) par ordinateur. (a) Les examens de thorax ont révélé la présence d'un nodule du lobe inférieur droit mesurant 3,2 2,3 cm. (b) Les scans abdominaux ont montré une masse gastrique située dans le cardia gastrique qui mesurait 5,2 5,0 cm.[21]

2.1.3 CARCINOME PULMONAIRE À GRANDES CELLULES : [22]

Le carcinome pulmonaire à grandes cellules représente une forme rare et agressive de cancer du poumon classée parmi les cancers bronchopulmonaires non à petites cellules (CBNPC).

Il présente une

morphologie peu distincte, dépourvue des caractéristiques histologiques typiques de l'adénocarcinome, du carcinome épidermoïde, ou du carcinome à petites cellules.

il expose :

- De grandes cellules tumorales avec un cytoplasme riche et des noyaux saillants.
- Une absence de différenciation glandulaire, squameuse ou neuroendocrine observable à l'immunohistochimie classique.




Figure I-12 : Carcinome à grandes cellules de haute qualité, non différencié, situé dans le segment apical et mesurant 2,5 cm en dimension maximale, montrant un effet radiothérapie/chimiothérapie. La tumeur se prolonge dans la paroi thoracique, A :coupe axiale sans produit contraste , B :coupe axiale avec produit contraste

2.2 Les cancers bronchiques à petites cellules (CBPC) :

Décrit pour la première fois en 1926 par Barnard, 6,79 le CBPC présente des traits neuroendocriniens et est le type de cancer du poumon le plus agressif, avec une nature dépressive 5- taux de survie annuel en dessous de 5 %. Bien que la cellule d'origine n'ait pas été formellement identifiée, il est supposé que les cellules neuroendocrines pulmonaires et leurs précurseurs neuroendocriniens dans les poumons contribuent à l'augmentation du CBPC et du carcinome neuroendocrinien à grandes cellules (LCNEC). Ces néoplasies représentent environ 15 % des cancers pulmonaires.[20]

Propriétés:

- Caractéristiques neuroendocriniennes
- Croissance rapide
- Forte association avec le tabagisme et les personnes âgées
- âge

- Métastatique à la présentation; par conséquent, la plupart des CBPC sont gérés principalement par chimiothérapie et radiothérapie
- Les CCSP sont gérés principalement par la chimiothérapie et la radiothérapie
- Association avec les syndromes paranéoplasiques (par exemple, Eaton-Lambert ou sécrétion inappropriée de l'hormone antidiurétique)
- Mutations dans TP53 et RB1 avec perte de CDKN2A dans la plupart des cas
- Perte de PTEN et activation de la voie PI3K dans un sous-ensemble de cas
- La maladie métastatique extrathoracique est trouvée à l'autopsie chez plus de 95 % des patients




Figure I-13: Cancer du poumon à petites cellules avec de multiples nodules pulmonaires et des métastases nodulaires médiastinales étendues. A: coupe coronale, B: coupe axiale sans P contraste

2.3 Classification TNM:

La stadification des tumeurs est un aspect essentiel des soins aux patients parce qu'il permet la classification de la maladie étendue et prise de décisions éclairées et le pronostic. Il fournit également un système qui facilite une communication cohérente entre cliniciens, chercheurs et patients. Les Syndicats L'Union Internationale Contre le Cancer (UICC) et l'American Joint Committee on Cancer (AJCC) pour la classification TNM de lutte contre le cancer est la norme internationalement acceptée pour le cancer la mise en scène. La catégorie T définit la taille et/ou étendue de la tumeur primaire; la catégorie N définit l'atteinte des ganglions lymphatiques régionaux, et le M catégorie définit la présence de métastases distantes.[18]

Catégorie	Description	Détails
T (Tumeur primaire)	Taille et extension locale de la tumeur	- T1 : ≤ 3 cm, limité au poumon - T2 : > 3 cm ≤ 5 cm ou envahit la plèvre/bronches - T3 : > 5 cm ≤ 7 cm ou envahit la paroi thoracique - T4 : > 7 cm ou envahit des organes voisins
N (Ganglions lymphatiques)	Propagation aux ganglions lymphatiques	- N0 : Aucun ganglion atteint - N1 : Ganglions hilaires/péribronchiques atteints - N2 : Ganglions médiastinaux ipsilatéraux atteints - N3 : Ganglions controlatéraux/supraclaviculaires atteints
M (Métastases à distance)	Propagation du cancer à d'autres organes	- M0 : Pas de métastases - M1a : Nodules dans un autre lobe pulmonaire ou épanchement malin - M1b : Une seule métastase hors thorax - M1c : Métastases multiples dans plusieurs organes

Tableau I-2[18] : Classification TNM des cancers pulmonaires : Tumeur primaire, Ganglions lymphatiques et Métastases

3. Détection des lésions tumorales par Imagerie Tomodensitométrique (TDM)

3.1.Principe de la TDM:

La tomodensitométrie (TDM) est une technique d'imagerie anatomique en radiologie. Permettant d'acquérir des sections transversales, reconstituées à partir de la mesure de la réduction d'un faisceau de rayons X à travers le volume analysé. Cette option est l'une des examens radiologiques les plus efficaces pour l'analyse du thorax et de l'abdomen.



Figure I-14: L'appareil du scanner. [19]

3.1.1. Principe de formation de l'image :

Le scanner est un dispositif radiologique constitué d'un générateur et d'un tube à rayons X et d'une série de détecteurs agencés en couronne. Le fondement s'appuie sur l'évaluation de l'atténuation d'un faisceau de rayons X qui pénètre un segment du corps. Le tube ainsi que les détecteurs tournent autour de l'objet à analyser (FigureI-14). De nombreux profils des niveaux d'atténuation sont atteints à divers angles de rotation. Ils sont prélevés et numérisés. Les informations sont sélectionnées et projetées en arrière sur une matrice de reconstruction en suite converties en image.[19]




Figure I-15: tubes et détecteurs qui tournent autour du patient. [19]

3.1.1.1. Atténuation:

Un faisceau de rayons X passant à travers un objet homogène d'épaisseur x subit une atténuation, selon la densité de l'objet. La valeur de l'atténuation se calcule par Différence entre l'intensité du faisceau de rayons X avant et après le passage à travers l'objet. Elle est formulée par la loi de Beer Lambert :

$$I = I_0 \cdot e^{-\mu x} \quad (I-1)$$

I_0 : intensité incidente du faisceau

I : intensité émergente

μ : coefficient d'atténuation

x : épaisseur de l'objet.

3.1.1.2. Échelle Hounsfield :

Les coefficients d'atténuation linéique (μ) varient en fonction du spectre des rayons X, qui dépend lui-même du kilovoltage (kV) appliqué et des filtres placés à la sortie du tube à rayons X. Plutôt que d'utiliser ces coefficients bruts, Hounsfield a proposé une normalisation en les rapportant au coefficient d'atténuation linéique de l'eau, selon la formule suivante :

$$\text{valeur_CT} = \frac{\mu_{\text{eau}} - \mu}{\mu} \times 1000 \quad (I-2)$$

La valeur obtenue s'exprime en unités Hounsfield (UH). On peut remarquer qu'en considérant l'atténuation de l'air comme nulle, on obtient $-1\,000$ UH pour l'air et 0 UH pour l'eau, ce qui représente deux points caractéristiques. Tous les tissus se répartissent sur une échelle partant de $-1\,000$ jusqu'à plusieurs milliers [19].

3.1.1.3. Projections:

Le détecteur convertit les photons X en un signal électrique, dont l'intensité est directement proportionnelle à celle du faisceau de rayons X reçu. L'ensemble des signaux électriques générés par tous les détecteurs pour un angle de rotation donné constitue le profil d'atténuation ou projection. Afin de reconstruire une image d'un volume complexe, plusieurs projections doivent être acquises sous différents angles autour du patient, ce qui est rendu possible par la rotation complète à 360° du système tube-détecteur. [22]




Figure I-16: Principe de la projection.[19]

3.1.1.4. Rétroprojection:

Les projections sont d'abord échantillonnées et numérisées, transformant les données acquises en valeurs numériques associées à une position spatiale. Avec un ensemble de n projections obtenues sous différents angles, il devient possible de reconstruire une image de la coupe étudiée. Ces projections subissent ensuite un filtrage, puis sont rétro-projetées sur une matrice de reconstruction, en respectant l'angle initial d'acquisition. À partir des valeurs d'atténuation mesurées par chaque détecteur, l'ordinateur calcule la densité de chaque pixel de l'image finale. Ce processus repose sur un principe fondamental : en connaissant la somme des valeurs d'une matrice selon plusieurs directions (lignes, colonnes, diagonales), il est possible de reconstituer les valeurs individuelles contenues dans cette matrice [22].

3.1.1.5. Passage de la matrice à l'image :

La matrice de reconstruction est une grille composée de n lignes et n colonnes, définissant un ensemble de petites unités élémentaires appelées pixels. Les matrices utilisées en tomodensitométrie sont généralement de 512×512 pixels. Chaque pixel correspond à une valeur

d'atténuation ou de densité, qui est convertie en une échelle de gris pour l'affichage de l'image. Ces valeurs sont exprimées en unités Hounsfield (UH), permettant de différencier les types de tissus. L'échelle s'étend de -1000 UH à +1000 UH, avec des repères caractéristiques : 0 UH pour l'eau, -1000 UH pour l'air et +1000 UH pour le calcium.

Deux paramètres modulables permettent d'ajuster cette fenêtre :

Le niveau : correspond à la valeur centrale des densités affichées.

La largeur de la fenêtre: détermine l'amplitude des niveaux de densité visibles.

Effet de la largeur de fenêtre :

- Large fenêtre → Plus de niveaux de gris visibles, mais réduction du contraste entre les structures.
- Fenêtre étroite → Moins de niveaux de gris affichés, mais amélioration du contraste, facilitant la différenciation des tissus.

3.1.2. Composants et technologie du scanner TDM [23]

3.1.2.1. Générateur de tube à rayons X :

Le générateur fournit l'énergie nécessaire au tube à rayons X, en délivrant une haute tension continue comprise entre 80 à 140 kV, ainsi qu'un courant constant variant de 10 à 500 mA. Sa puissance totale, située entre 50 à 60 kW, permet d'assurer un fonctionnement optimal du système d'imagerie. Le générateur est intégré au statif, garantissant ainsi une alimentation stable et sécurisée du tube à rayons X.

3.1.2.2. Tube:

Les tubes à rayons X utilisés en tomodensitométrie doivent présenter des performances élevées afin de répondre aux exigences de l'imagerie médicale. Ils doivent notamment être capables de:

1. Supporter d'importantes contraintes thermiques, ce qui nécessite une capacité calorifique élevée, exprimée en unités chaleur (UC).
2. Évacuer efficacement la chaleur grâce à un système de dissipation thermique performant, permettant ainsi d'enchaîner rapidement une nouvelle acquisition en hélice après une charge thermique maximale.

Ces tubes sont conçus avec une anode tournante et un double foyer, dont la taille varie entre 0,5 et 1,5 mm, garantissant une émission continue des rayons X. De plus, ils doivent être capables de résister aux forces mécaniques générées par la force centrifuge des statifs de dernière génération, qui atteignent une vitesse de rotation de 360° en seulement 0,4 seconde.

2.1.1.1. Filtration et collimation:

La filtration et la collimation assurent le façonnage du faisceau de rayons X, optimisant ainsi sa qualité et son utilisation en imagerie médicale.

2.1.1.1.1. Filtration des rayons X:

La filtration est réalisée à l'aide d'une lame métallique de faible épaisseur, permettant de restreindre le spectre de rayonnement et de se rapprocher d'une émission quasi-monochromatique. Afin d'optimiser l'homogénéité de l'irradiation, un deuxième filtre, dont l'épaisseur est plus importante au centre qu'en périphérie, est fréquemment ajouté. Cette disposition permet d'adapter le profil du faisceau X aux variations d'épaisseur du volume traversé, qui est généralement plus faible en périphérie qu'au centre.

3.1.2.2.1. Collimations primaire et secondaire:

La collimation primaire, positionnée en aval du système de filtration, joue un rôle essentiel dans le calibrage du faisceau de rayons X en fonction de l'épaisseur de coupe souhaitée. Son principal objectif est de réduire l'irradiation inutile, optimisant ainsi la qualité de l'image tout en minimisant l'exposition du patient.

Certains dispositifs intègrent également une collimation secondaire, placée avant le détecteur. Celle-ci doit être rigoureusement alignée avec le foyer et la collimation primaire afin d'atténuer le rayonnement diffusé par le patient. De plus, elle peut contribuer à la détermination précise de l'épaisseur d'acquisition, garantissant ainsi une imagerie plus fiable et optimisée. (figure.17)




Figure I -17: Collimation primaire et secondaire.[19]

3.1.2.2.2. Collimateurs de champ:

Les collimateurs de champ, placés à la sortie du tube à rayons X, ont pour fonction de restreindre automatiquement le faisceau de rayonnement à la zone d'intérêt sélectionnée. Au lieu d'exposer l'ensemble du volume anatomique, ils ajustent précisément l'étendue du faisceau afin de n'enregistrer que les données d'absorption pertinentes. Cette régulation permet non seulement de réduire l'irradiation inutile, mais aussi d'optimiser la qualité des images obtenues, tout en minimisant l'exposition aux rayonnements pour le patient.

3.1.3. Système de detection:

Les détecteurs transforment les photons X en signal électrique. On distingue deux types de détecteurs.[23]

3.1.3.1. Détecteur à gaz:

Il s'agit d'une chambre gazeuse sous pression, généralement remplie de xénon sous une pression de 10 à 20 bars. À l'intérieur, des électrodes plates délimitent un ensemble de cellules de mesure, dont le nombre varie entre 700 à 1000. Ces détecteurs se distinguent par un faible espacement entre les cellules, optimisant ainsi leur capacité à capturer les rayons X avec une efficacité de détection élevée.[24]

Les photons X sont convertis directement en signal électrique, bien que leur efficacité de conversion demeure relativement faible, avec une absorption de seulement 60 à 70 % de l'énergie incidente. En raison de ce rendement limité, ces détecteurs ne sont plus utilisés dans les systèmes d'imagerie modernes et ont été progressivement remplacés par des détecteurs solides, offrant une meilleure performance et une plus grande sensibilité.[25]

3.1.3.2. Détecteurs solides:

Ces détecteurs sont largement adoptés dans les scanners modernes en raison de leur haute performance. Les photons X sont d'abord absorbés par un scintillateur céramique, qui les convertit en photons lumineux. Ces derniers sont ensuite transformés en signal électrique par une photodiode. Ce procédé garantit une efficacité optimale, caractérisée par des temps de réponse rapides et une faible rémanence, contribuant ainsi à une acquisition d'images de haute précision et à une réduction des artefacts.[25]

3.1.4. Les Risques:

Ils peuvent être dus, soit aux rayons X, soit au produit de contraste.

- Les rayons X sont sans danger, du fait des très faibles doses utilisées à court terme. Des précautions seront prises chez les femmes enceintes.
- L'administration d'un produit de contraste peut, dans de rares cas, induire une réaction allergique. Chez les patients présentant une hypersensibilité à l'iode, une prémédication antihistaminique et corticostéroïde, administrée la veille et le jour de l'examen, permet de réduire significativement le risque de réaction allergique.

3.1.5. Rôle de la TDM:

La tomодensitométrie (TDM) est une technique d'imagerie médicale permettant l'exploration détaillée du cerveau, de la cage thoracique, de l'abdomen et du système osseux. Elle est particulièrement indiquée pour la détection d'anomalies non visibles sur les radiographies conventionnelles ou l'échographie, Il permet de :

- Mettre en évidence des infections, une hémorragie, des kystes, des tumeurs, des ganglions.
- Localiser avec précision un organe, par rapport à un autre, de définir le trajet d'un vaisseau.
- Guider des ponctions d'organes profonds, évitant une intervention chirurgicale.

3.2. Tomодensitométrie du Thorax:

La tomодensitométrie (TDM) thoracique, connue sous le nom de scanner thoracique, est une méthode d'imagerie médicale qui emploie des rayons X pour obtenir des images précises des

structures thoraciques, y compris les poumons, le cœur, les vaisseaux sanguins, la trachée, l'œsophage et les structures osseuses (côtes, sternum, colonne vertébrale).

il existe plusieurs types de tomodensitométrie (TDM) thoracique :

- TDM thoracique standard.
- TDM thoracique avec injection de produit de contraste.
- Angioscanner thoracique.
- TDM haute résolution (HRCT ou TDMHR).
- TDM 4D ou synchronisé avec la respiration.

3.2.1. TDM Thoracique à Visée Diagnostique [23]

La tomodensitométrie (TDM) thoracique à visée diagnostique constitue un pilier fondamental de l'imagerie médicale, offrant une exploration détaillée des structures thoraciques. Elle occupe une place prépondérante dans l'identification des anomalies, l'analyse des schémas pathologiques et la confirmation diagnostique, garantissant ainsi une meilleure orientation clinique et thérapeutique.

3.2.1.1. Détection des Anomalies

La TDM thoracique représente un instrument diagnostique de premier plan dans l'identification des anomalies pulmonaires, incluant les nodules, les masses et les opacités. Grâce à sa haute résolution, elle permet une caractérisation précise des lésions en termes de taille, de localisation et de structure, optimisant ainsi leur classification et leur suivi. Cette imagerie avancée joue un rôle déterminant dans la différenciation entre lésions bénignes et malignes, contribuant ainsi à l'élaboration de stratégies thérapeutiques adaptées et personnalisées.

3.2.1.2. Modèles de Maladie

L'imagerie TDM joue un rôle essentiel dans la reconnaissance des schémas caractéristiques des maladies pulmonaires interstitielles. Les opacités en verre dépoli, par exemple, constituent un marqueur radiologique significatif de pathologies telles que la fibrose pulmonaire. L'évaluation de ces modèles d'imagerie est primordiale pour affiner le diagnostic, adapter la prise en charge thérapeutique et assurer un suivi rigoureux de l'évolution des affections pulmonaires chroniques.

3.2.1.3. Validation des Diagnostics

La TDM thoracique constitue un outil diagnostique complémentaire aux autres modalités d'imagerie, notamment la radiographie pulmonaire. Grâce à sa capacité à fournir des images en coupes fines et en trois dimensions, elle améliore significativement l'interprétation des anomalies détectées. Cette précision accrue permet d'optimiser la prise en charge clinique et thérapeutique, en particulier dans le cadre des pathologies pulmonaires malignes et des affections vasculaires thoraciques, où une évaluation détaillée est essentielle pour orienter les décisions thérapeutiques.

3.2.2. TDM Thoracique à Visée thérapeutique

La tomodensitométrie (TDM) thoracique ne se limite pas à une fonction purement diagnostique ; elle joue également un rôle essentiel en tant qu'outil thérapeutique en imagerie médicale. Elle est utilisée pour orienter les interventions mini-invasives, optimiser les stratégies thérapeutiques et assurer le suivi de l'efficacité des traitements en cours.

3.2.2.1. Guidage des Procédures Interventionnelles

L'un des principaux usages thérapeutiques de la TDM thoracique réside dans son rôle de guidage des actes interventionnels ciblés. Elle permet ainsi d'assurer une précision optimale dans diverses procédures, parmi lesquelles :

3.2.2.1.1. Biopsies percutanées :

Réalisées sous contrôle TDM, elles permettent le prélèvement d'échantillons tissulaires de nodules ou de masses suspectes, facilitant ainsi l'établissement d'un diagnostic histologique précis.[26]

3.2.2.1.2. Drainage pleural :

Cette technique est employée pour l'évacuation des épanchements pleuraux, des abcès pulmonaires ou des collections liquidiennes intrathoraciques, réduisant ainsi les risques de complications.[27]

3.2.2.1.3. Ablations tumorales :

Effectuées sous guidage TDM par radiofréquence ou cryothérapie, ces interventions permettent un traitement ciblé des lésions pulmonaires primitives ou secondaires, tout en minimisant l'atteinte des tissus sains avoisinants.[28]

3.2.2.1.4. Planification et Suivi des Traitements

La TDM thoracique est utilisée pour planifier et adapter certains traitements, notamment en oncologie thoracique. Elle permet:

- **La planification de la radiothérapie** : en délimitant précisément les volumes tumoraux à irradier tout en préservant les tissus sains.
- **Le suivi de la chimiothérapie ou de l'immunothérapie** : en évaluant l'évolution des lésions tumorales et la réponse thérapeutique.
- **Le contrôle post-opératoire** : en détectant d'éventuelles complications après une chirurgie thoracique.

4. Radiothérapie externe:

4.1.Enjeux de la radiothérapie guidée par l'imagerie TDM : [29, 30]

4.1.1. Précision du ciblage:

La radiothérapie doit tenir compte des variations anatomiques qui peuvent se produire entre les séances ou même pendant les séances d'irradiation. La tomodensitométrie permet d'évaluer précisément la position du volume tumoral et des organes à risque, ce qui est crucial pour maximiser le contrôle local et minimiser la toxicité.

4.1.2. Marge de sécurité:

La définition de marges autour du volume tumoral, nécessaire pour prendre en compte les incertitudes de positionnement et les variations de forme ou de volume, est souvent empirique. L'imagerie TDM aide à rationaliser ces marges en fournissant des données précises sur les variations anatomiques.

4.1.3. Optimisation des traitements:

L'intégration de la TDM dans le processus de planification et d'administration des traitements peut conduire à une meilleure adaptation de la thérapie en temps réel et potentiellement à une nouvelle planification si des variations significatives sont détectées.

II. Chapitre II : État de l'art

1. Les méthodes de segmentation des volumes tumoraux broncho-pulmonaires : Revue des approches proposées pour la détection automatique des contours des volumes cibles tumoraux.

1.1.Introduction:

La segmentation des tumeurs pulmonaires constitue un défi majeur dans le diagnostic et la prise en charge du cancer du poumon, notamment en radiothérapie. Elle permet de définir avec précision les structures cibles à irradier. Toutefois, cette tâche est compliquée par l'irrégularité des contours tumoraux, la diversité des formes et l'hétérogénéité des textures entre les patients. Ces caractéristiques anatomiques rendent la segmentation difficile, particulièrement lorsqu'on utilise des méthodes classiques telles que le seuillage automatique ou la détection de contours, souvent inefficaces sur des images à faible contraste ou présentant des frontières floues.[31, 32]

Des études récentes ont démontré que ces méthodes traditionnelles peuvent entraîner des erreurs significatives, compromettant la précision des traitements. Il est donc devenu essentiel d'explorer des approches plus robustes, notamment celles basées sur l'apprentissage profond. Ces techniques permettent d'améliorer la qualité des segmentations en s'adaptant à la complexité morphologique des tumeurs, et ont montré des résultats prometteurs dans plusieurs recherches, en particulier avec l'utilisation de modèles avancés.[33]

En revanche, les réseaux de neurones profonds, en particulier les architectures avancées comme les réseaux de neurones convolutifs (CNN) et leurs variantes telles que U-Net et Mask R-CNN, ont démontré leur efficacité dans l'amélioration de la précision de la segmentation des tumeurs, grâce à leur capacité à apprendre directement à partir de larges bases de données médicales annotées.

1.2.L'intelligence artificielle:

L'intelligence artificielle est principalement définie comme l'ensemble des techniques du deep learning aux technologies cognitive permettant aux machines d'interagir efficacement avec les utilisateurs, d'analyser des données et de répondre ou prendre des décisions contextualisées dans des conversations digitales. [34]

1.3.Apprentissage profond:

L'apprentissage profond est une sous-catégorie de l'apprentissage automatique (machine learning) qui repose sur l'utilisation de réseaux de neurones artificiels profonds, c'est-à-dire composés de plusieurs couche hiérarchiques.

Ces réseaux permettent d'apprendre automatiquement des représentations complexes à partir de données brutes (images, sons, textes), sans avoir besoin d'une extraction manuelle des caractéristiques.[35]

1.4.Méthodes de segmentation basées sur l'apprentissage profond :

Shuvo, S. B et al [36] ont proposé un système pour accomplir trois challenges, notamment, segmentation des coupes pulmonaires susceptibles de présenter des lésions tumorales, et ce en utilisant l'architecture 3D Res-U-Net. Ce réseau permet d'utiliser un très grand nombre de couches hybridée avec un « Residual block », qui sert à parer contre la disparition du gradient, car il permet d'envoyer l'activation depuis les couches inférieures vers les couches extérieures, ils ont rapporté un coefficient de Dice de 98,82% sur la base des données **LUNA16** (LUNG Nodule Analysis 2016). Le deuxième bloc de leur système consiste à utiliser **YOLO-v5 [37]** pour la détection des régions d'intérêts représentant des nodules tumorales et le dernier bloc du modèle est dédié à la classification de la sévérité des nodules pulmonaires en exploitant une architecture d'apprentissage profond distincte, les **Vision Transformers (ViT)[38]**. Contrairement aux réseaux de neurones convolutifs (CNN), ces modèles segmentent l'image en multiples patches et exploitent un mécanisme d'auto-attention pour capturer les relations spatiales à longue portée. Leur approche a permis d'atteindre une précision de classification des nodules cancéreux de **93,57 %**, surpassant ainsi les performances des méthodes existantes.

Et dans un article de synthèse élaboré par **Jun Hung et al [39]** portant sur l'analyse des travaux pertinents, publiés récemment, dans le contexte de segmentation du cancer des poumons. L'ensemble des approches présentées ont été testé sur différentes base de données qui présentent des modalités différentes (Tomodensitométrie, PET IRM,). Les résultats ont montré que la plupart des valeurs du coefficient de similarité de Dice (DSC) pour la segmentation des tumeurs pulmonaires étaient supérieures à 0,7. Deux études [29, 40] se sont distinguées par des performances remarquables, atteignant des coefficients de Dice respectifs de 0,85 et 0,86. Le dénominateur commun entre ces travaux résidait dans l'exploitation d'une base de données

multimodale intégrant des images TEP (PET) et TDM (CT), ainsi que dans l'adoption d'architectures entièrement convolutionnelles (Fully Convolutional Networks, FCN) comme méthode d'apprentissage.

Et en [41] **M. F. Serj, B., et al.**, ont utilisé des réseaux de neurones convolutionnels (CNN) pour la détection et la segmentation automatiques des tumeurs dans des images de tomodensitométrie (TDM). Ces modèles ont été développés et validés sur la base de données Kaggle Data Science Bowl 2017 (KDSB17).

Dans cette même dynamique **Zineb Riaz et al**[42] ont développé une méthode hybride combinant MobileNetV2 en tant qu'encodeur au sein de l'architecture U-Net pour la segmentation des tumeurs pulmonaires. L'approche repose sur l'apprentissage par transfert, permettant d'extraire efficacement les caractéristiques tout en conservant un faible coût computationnel. Concernant le prétraitement des données, les images CT 3D du **Medical Segmentation Decathlon (MSD) 2018 Challenge** ont été converties en 2D, redimensionnées à 256×256 pixels et normalisées afin d'améliorer la qualité des entrées et d'optimiser l'apprentissage du modèle. Les performances du modèle ont été évaluées en utilisant un ensemble de test représentant 25% de la base de données extraite, ce qui a permis d'obtenir un coefficient de dice de 0.87 et une précision de 0.93.

Par ailleurs, **Liu, M., et al.**, [43] ont proposé une approche basée sur Mask R-CNN (Region-based Convolutional Neural Network) + ResNet, capable de localiser et segmenter avec précision les nodules sur des images CT 2D. Le traitement est bien structuré, avec un bon équilibre entre filtrage, classification et segmentation pixel-par-pixel. Leur approche a été testée sur la base de données LIDC-IDRI (*Lung Image Database Consortium and Image Database Resource Initiative*). Leur modèle a atteint une précision moyenne de ($mAp = 0.79$), démontrant son efficacité pour la segmentation des structures complexes en imagerie médicale.

Le modèle proposé dans cette étude repose sur plusieurs composantes essentielles. L'utilisation de la base de données **LIDC-IDRI**, comprenant 1 018 scanners CT annotés, a permis un entraînement rigoureux du réseau, contribuant à la réduction des erreurs de segmentation. L'architecture **Mask R-CNN**, particulièrement adaptée à la détection d'objets complexes, a optimisé simultanément la localisation et la segmentation précise des nodules pulmonaires. Par ailleurs, un apprentissage supervisé basé sur des annotations expertes a renforcé

la fiabilité du modèle. Enfin, l'intégration de techniques de prétraitement, telles que la normalisation des images et l'augmentation des données, a amélioré sa robustesse face à la variabilité anatomique.

Dans le prolongement de ces travaux **Kalinovsky et al [44]** ont mis en œuvre des réseaux de neurones convolutionnels profonds (Deep Convolutional Networks), pour la classification et la détection des cancers pulmonaires à partir des images TDM, les auteurs ont utilisé un ensemble de données composé de 201 images pulmonaires. Ces images ont été divisées en deux groupes : 85% pour l'entraînement du modèle et 15% pour les tests et la classification.,la mesure de la performance du modèle en présentant non seulement l'exactitude globale (90,85 %), mais également les précisions individuelles pour plusieurs images testées. Cette approche souligne l'importance de l'évaluation fine des résultats, permettant de détecter les écarts de performance selon la complexité des cas cliniques, démontrant ainsi l'efficacité des CNNs dans l'analyse des images tomodensitométriques. Les résultats de cette étude s'expliquent par plusieurs facteurs. La taille restreinte de la base de données (201 images pulmonaires) a limité la diversité des cas, impactant la généralisation du modèle. Le partitionnement des données (85% pour l'entraînement et 15% pour les tests) a permis un apprentissage approfondi, mais avec une validation réduite. L'utilisation d'un modèle d'apprentissage profond basé sur les CNN a facilité l'extraction des caractéristiques des images TDM. De plus, l'application de techniques de prétraitement (normalisation, amélioration du contraste) a renforcé la précision du modèle. Enfin, l'optimisation des hyperparamètres a permis d'améliorer ses performances globales.

Dans le même article rédigé par **Jun Hung et al [39]**, où ils ont étudié le développement de **CT-umorGAN**, un cadre d'apprentissage adversarial conçu pour la segmentation des tumeurs sur les images CT.Ce modèle a été évalué à l'aide de la base de données **LIDC-IDRI** et a obtenu un coefficient de similarité de Dice (DSC) de 71,08%[40],attestant d'une bonne précision et stabilité dans la segmentation. Ce score a été déterminé en comparant les résultats de segmentation du modèle avec les annotations fournies par des experts dans la base de données. Malgré ces résultats encourageants, l'étude souligne certaines limitations, notamment dans la segmentation des tumeurs présentant des variations de forme et de contraste. Elle recommande que les recherches futures portent sur l'amélioration de la robustesse du modèle et son intégration à des protocoles cliniques pour une évaluation approfondie.

Étude / Auteurs	Méthode / Modèle	Base de Données	Performance (Dice / Précision / Autres)	Avantages/Innovations
Shuvo, S. B. et al.	3D Res-U-Net + YOLOv5 + Vision Transformers	LUNA16	Dice : 98,82% ;Précision : 93,57%	Approche multi-étapes : segmentation, détection, classification
Jun Hung et al. (revue)	FCN + multimodalité (CT + PET)	Plusieurs (CT, PET, IRM...)	Dice jusqu'à 0,86	Approchemultimodale très efficace
M.F. Serj, B. et al.	CNN	Kaggle (KDSB17)	Non précisé	Application directe sur TDM, segmentation automatique
Zineb Riaz et al.	U-Net avec MobileNetV2 (encodeur)	MSD 2018	Dice :0.87 ;Précision : 0.93	Apprentissage par transfert ; faible coût computationnel
Liu, M. et al.	Mask R-CNN + ResNet	LIDC-IDRI	mAP : 0.79	Segmentation + détection ; segmentation pixel-par-pixel
Kalinovsky et al.	CNN profonds	Ensemble de 201 images	Précisionglobale : 90,85%	Taille de base limitée, bon prétraitement et optimisation
Jun Hung et al. (CT-umorGAN)	GAN pour segmentation tumorale	LIDC-IDRI	Dice : 71,08%	Bonne stabilité, mais difficultés sur les formes/contrastes complexes

TableauII-1: Résumé comparatif des méthodes de segmentation pulmonaire basées sur l'apprentissage profond

1.5.Conclusion :

Les techniques de segmentation d'images basées sur l'apprentissage profond ont fourni des outils puissants pour le dépistage précoce des tumeurs pulmonaires et ont amélioré la planification des traitements. L'amélioration continue des réseaux de neurones, en particulier les réseaux neuronaux convolutifs (CNN), a permis d'atteindre des niveaux élevés de précision dans la segmentation des tumeurs.

Les résultats de nombreuses études montrent l'efficacité de ces techniques pour la segmentation des tumeurs pulmonaires et leur intégration dans les systèmes de radiothérapie et de suivi thérapeutique. L'évolution de ces nouvelles méthodes, associée à l'augmentation de l'accès aux données médicales, permet d'offrir des soins de santé plus rapides, plus précis et mieux adaptés aux besoins des patients.

III. Chapitre III: Matériel et méthodologie

1. Introduction:

Ce chapitre introduit les bases théoriques nécessaires à la compréhension de notre approche de segmentation des tumeurs pulmonaires. Il présente la base de données Lung issue du Medical Segmentation Decathlon, les fondements du deep learning, les architectures de réseaux neuronaux (MLP, CNN, U-Net), ainsi que l'intégration des mécanismes d'attention. Enfin, il expose les principales métriques d'évaluation utilisées pour mesurer la performance des modèles de segmentation.

2. Base de données

Pour les besoins de cette étude, nous avons utilisé la base de données "**Lung**" issu du **Medical Segmentation Decathlon (MSD)**, une initiative internationale visant à promouvoir le développement de méthodes robustes de segmentation d'images médicales. Ce jeu de données, publié par Antonelli et al. (2022)[45], offre un ensemble d'images tomodensitométriques de haute qualité permettant la comparaison équitable d'algorithmes sur différentes modalités d'imagerie et pathologies.

Le jeu de données cancer des poumons comprend 96 volumes 3D d'images tomodensitométriques (CT) thoraciques, répartis en 64 volumes pour l'apprentissage et 32 pour les tests, les dimensions de chaque coupe est de 512×512 pixels, avec une profondeur de 100 à 300 coupes par patient (selon la taille du champ pulmonaire).

Ces données concernent exclusivement des patients atteints de cancer du poumon non à petites cellules (CBNPC), et incluent pour chaque volume un masque d'annotation correspondant à la tumeur.

Les images sont fournies au format NIfTI(.nii.gz) et présentent une structure tridimensionnelle (3D), conforme aux exigences des modèles de segmentation volumique. Les figures suivantes (figure I I I 1, figure I I I 2) montre un exemple de ces images :




Figure I I I -1: Image de TDM d'un cas normal de la base de données DMC




Figure I I I -2: Image de TDM d'un cas pathologique de la base de données DMC

Les données sont mises à disposition en accès libre via le site officiel du MSD (www.medicaldecathlon.com), sous licence Creative Commons BY-SA 4.0, facilitant ainsi leur utilisation dans un cadre académique et expérimental.

La pertinence de cette base de données dans le contexte du cancer du poumon repose sur plusieurs critères : elle regroupe des cas réels, annotés de manière rigoureuse, et reflète la variabilité morphologique importante des tumeurs pulmonaires. Cette diversité constitue un atout majeur pour l'entraînement et l'évaluation de modèles d'apprentissage profond destinés à la segmentation automatique des lésions, en particulier dans un objectif de planification radiothérapeutique ou de diagnostic assisté par l'intelligence artificielle.[46]

Caractéristique	Description
Nom de la base	Medical Segmentation Decathlon (MSD) – Task 06: Lung
Nombre total de volumes	96 volumes TDM thoraciques
Répartition	64 volumes pour l'apprentissage, 32 pour les tests
Type d'images	Images tomodensitométriques (CT), format NIfTI(.nii.gz)
Dimensions des images	512 × 512 pixels par coupe, 100 à 300 coupes par patient
Structure	Images tridimensionnelles (3D)
Type de cancer	Cancer broncho-pulmonaire non à petites cellules (CBNPC)
Annotations	Masques de segmentation manuels des lésions tumorales
Origine des données	Cas réels de patients
Licence	Creative Commons BY-SA 4.0
Accessibilité	Données disponibles en libre accès sur medicaldecathlon.com
Utilisation prévue	Segmentation des lésions, diagnostic assisté, planification en radiothérapie

Tableau III-1: Caractéristiques de la base de données utilisée

3. Notions de l'apprentissage profond

3.1. Perceptron multi-couche

3.1.1. Neurone formel:

Le neurone artificiel constitue l'unité fondamentale de tout réseau de neurones artificiels. Son architecture et ses mécanismes de fonctionnement s'inspirent directement de l'observation du neurone biologique, qui représente l'élément de base des réseaux neuronaux biologiques, notamment ceux composant le cerveau, la moelle épinière et les ganglions périphériques. Cette analogie entre les deux types de neurones est illustrée dans la figure 1 : la partie gauche de la figure montre un neurone biologique, comprenant le soma, les dendrites et l'axone, tandis que la partie droite représente un neurone artificiel, caractérisé par ses entrées, ses poids synaptiques, sa fonction de transfert, ses biais et sa sortie.[46]




Figure I I I -3: Conception de neurones biologiques et artificiels.

Dans un neurone biologique, l'information est transmise par l'intermédiaire des dendrites vers le soma, qui en assure le traitement, avant d'être relayée via l'axone vers d'autres cellules. Par analogie, un neurone artificiel reçoit des signaux d'entrée qui sont chacun associés à un poids synaptique. Ces entrées pondérées sont ensuite additionnées, accompagnées d'un biais, puis soumises à une fonction de transfert (ou d'activation) qui détermine la sortie du neurone. Cette modélisation, bien que simplifiée par rapport à la complexité des systèmes neuronaux biologiques, présente l'avantage d'une formalisation mathématique claire et efficace, comme illustré ci-dessous[46].

$$Y_i(K) = F\left(\sum_{i=0}^M W_i(K).X_i(K) + B\right) \quad (\text{III-1})$$

$X_i(K)$:est la valeur d'entrée en temps discret où va de 0 à m.

$W_i(K)$:est la valeur de poids en temps discret où va de 0 à m.

B : est un biais.

F :est la fonction de transfert.

$Y_i(K)$: est la valeur de sortie en temps discret K.

Comme le montre le modèle du neurone artificiel et son équation associée (équation 1), l'élément central et généralement inconnu de ce modèle est la fonction de transfert. Cette fonction, qui détermine le comportement du neurone artificiel, peut être définie par toute fonction mathématique adaptée à la tâche à accomplir. Son choix dépend de la nature du problème à résoudre par le réseau neuronal artificiel. Les fonctions de transfert les plus couramment utilisées sont la fonction seuil (ou fonction d'étape), la fonction linéaire et les fonctions non linéaires, telles que la fonction sigmoïde.

La fonction d'étape est une fonction binaire, caractérisée par deux valeurs de sortie possibles, généralement 0 et 1. Elle s'active uniquement lorsque l'entrée dépasse un certain seuil : si ce seuil est atteint ou dépassé, la fonction retourne une valeur, sinon une autre. Ce comportement peut être formalisé mathématiquement par l'équation (2).

$$Y = \begin{cases} 1 & \text{si } W_i X_i \geq \text{Seuil} \\ 0 & \text{si } W_i X_i < \text{Seuil} \end{cases}$$

Lorsqu'un neurone artificiel utilise une fonction de transfert de type seuil, on parle alors de perceptron. Ce type de neurone est particulièrement adapté à la résolution de problèmes de classification, raison pour laquelle il est le plus souvent placé dans la couche de sortie des réseaux de neurones artificiels.[46]

3.1.1.1. Perceptron multicouche:

Le Perceptron Multicouche (MLP) constitue une architecture classique des réseaux de neurones artificiels à propagation avant (*feedforward neural networks*). Il est composé d'une

couche d'entrée, d'une ou plusieurs couches cachées ainsi que d'une couche de sortie. À l'exception de la couche d'entrée, chaque neurone du réseau applique une fonction d'activation non linéaire à la somme pondérée de ses entrées. Ce type de réseau est largement utilisé pour des tâches de classification, de régression ou encore de reconnaissance de formes, en raison de sa capacité à modéliser des relations complexes entre les données d'entrée et les sorties attendues.

Sur le plan architectural, le MLP repose sur une structure entièrement connectée. La couche d'entrée reçoit les variables explicatives du jeu de données (par exemple : longueur et largeur de pétales dans le cas du jeu de données Iris). Les couches cachées, quant à elles, assurent des transformations successives sur les données, permettant l'extraction progressive de caractéristiques pertinentes. Enfin, la couche de sortie génère les prédictions finales. Le choix de la fonction d'activation dans cette dernière dépend du type de problème abordé : la fonction sigmoïde est souvent utilisée pour la classification binaire, tandis que la fonction softmax convient aux problèmes de classification multicatégorie.

Le fonctionnement d'un MLP repose sur deux étapes fondamentales. La première est la propagation avant (*forwardpass*), durant laquelle les entrées traversent le réseau jusqu'à la sortie, chaque neurone effectuant des calculs basés sur ses poids, biais et fonction d'activation. La seconde étape est la rétropropagation de l'erreur (*backwardpass*), qui ajuste les paramètres du réseau à l'aide d'un algorithme d'optimisation, généralement la descente de gradient stochastique, afin de minimiser la fonction de perte (par exemple, l'entropie croisée). Ce processus itératif permet au réseau d'apprendre à partir des erreurs commises et d'améliorer progressivement sa capacité de prédiction.

Les fonctions d'activation les plus courantes dans les MLP sont :

1. Sigmoid : adaptée aux tâches de classification binaire.
2. Softmax : utilisée pour la classification multiclasse.
3. ReLU (RectifiedLinear Unit) : populaire pour sa simplicité et ses performances dans les couches cachées.




Figure I I I -4: Exemple d'un MLP ayant deux couches cachées

3.1.1.2. Optimisation de l'apprentissage du MLP par des algorithmes :

L'entraînement réussi des perceptrons multicouches (MLP) dépend de l'optimisation des poids synaptiques et des biais, un processus qui impacte directement la capacité du réseau à généraliser et à atteindre une solution adéquate. En plus des techniques traditionnelles d'optimisation comme la descente de gradient, de nombreux algorithmes basés sur des principes naturels ont été étudiés pour renforcer l'efficacité d'apprentissage des MLP. Ces méthodes, dérivées de phénomènes biologiques, sociaux ou physiques, incluent notamment les algorithmes génétiques, l'optimisation par essais particuliers, l'algorithme de la colonie de fourmis, l'algorithme du feu follet, la recherche du coucou et la colonie d'abeilles artificielles.

Ces approches ont l'avantage de ne pas nécessiter le calcul de gradients, ce qui les rend résistantes aux problèmes de non-linéarité, de blocage dans des minima locaux et d'instabilité du paysage d'erreur. Elles recourent à des ensembles de solutions et des processus stochastiques de mise à jour pour parcourir l'espace de recherche, ce qui permet d'obtenir de meilleures performances en termes de précision et de rapidité de convergence. De ce fait, l'inclusion de ces algorithmes dans l'apprentissage des MLP représente une option intéressante par rapport aux méthodes classiques, surtout dans des contextes complexes et très non linéaires.

3.2.Réseaux de Neurones convolutifs[47]

Les réseaux de neurones convolutifs (CNN) représentent une architecture fondamentale de l'apprentissage profond, particulièrement adaptée au traitement des données visuelles.

la structure des réseaux de neurones convolutifs (CNN) repose sur les éléments suivants :

3.2.1. Couches de convolution :

La couche de convolution représente le cœur fonctionnel des réseaux de neurones convolutifs (CNN). Elle est spécialement conçue pour extraire automatiquement les caractéristiques locales d'une image en appliquant des filtres (ou noyaux) de petite dimension sur les données d'entrée. Chaque filtre, constitué d'un ensemble de poids, parcourt l'image selon un schéma défini (opération de convolution), générant en sortie une carte de caractéristiques (*featuremap*) qui met en évidence des structures visuelles spécifiques, telles que les bords, les angles ou encore les textures répétitives.




Figure I I I -5 schéma d'une convolution avec un noyau de taille 3*3 et un pas de 2

Sur le plan technique, la convolution consiste à effectuer, à chaque position du filtre, un produit scalaire entre les valeurs du filtre et les pixels de l'image couverts :

Suivi de l'application éventuelle d'une fonction d'activation non linéaire, généralement la fonction ReLU.

La fonction ReLU est définie mathématiquement comme suit :

$$f(x) = \max(0, x) \quad (\text{III-3})$$

Autrement dit, elle retourne zéro pour toutes les valeurs négatives de l'entrée et conserve les valeurs positives inchangées. Cette simplicité en fait une fonction légère en calcul et très efficace pour l'apprentissage profond.

Les paramètres de stride (déplacement du filtre) et de padding (gestion des bords) influencent directement la résolution spatiale des cartes produites.

Ce mécanisme d'extraction de caractéristiques est appris automatiquement durant l'entraînement du réseau, grâce à la rétropropagation de l'erreur, ce qui permet aux CNN de s'adapter dynamiquement aux données et à la tâche cible. Cette capacité d'apprentissage confère aux réseaux convolutifs une supériorité marquée par rapport aux approches classiques de détection manuelle, en particulier dans le traitement d'images complexes à haute variabilité.

3.2.2. Couches de pooling :

La couche de pooling, également désignée sous les appellations de sous-échantillonnage ou de réduction dimensionnelle, constitue une composante fondamentale des architectures de réseaux de neurones convolutifs (CNN). Positionnée immédiatement après les couches de convolution, elle a pour fonction principale de réduire les dimensions des cartes de caractéristiques (featuremaps), tout en préservant les informations les plus significatives. Cette opération contribue à diminuer la quantité de paramètres à apprendre ainsi que la complexité computationnelle du modèle, tout en atténuant les risques de surapprentissage.

Plusieurs méthodes de pooling sont employées dans la pratique, parmi lesquelles les plus courantes sont :

1. Le *max pooling*, qui sélectionne la valeur maximale au sein d'une région définie (souvent de taille 2×2) ;
2. L'*average pooling*, qui calcule la moyenne des valeurs contenues dans cette même région.

Le pooling agit ainsi comme un filtre de simplification, en retenant les traits les plus saillants tout en écartant les détails secondaires. Cette opération confère au réseau une plus grande robustesse face aux variations locales et aux déformations de l'image d'entrée.

3.2.3. Couches entièrement connectées :

Les couches entièrement connectées, aussi appelées couches denses, sont les dernières étapes dans un réseau de neurones convolutif (CNN). Elles reçoivent les informations extraites par les couches précédentes (convolution et pooling), transformées en un long vecteur.

Dans ces couches, chaque neurone est relié à tous ceux de la couche précédente. Cette structure permet de regrouper les informations pour produire un résultat, comme une prédiction dans une tâche de classification. La dernière couche a souvent autant de neurones que de classes possibles, et utilise une fonction comme softmax pour donner les probabilités de chaque classe.

Une fonction d'activation, souvent ReLU, est utilisée pour ajouter de la souplesse au modèle. La fonction utilisée à la fin dépend du type de tâche : par exemple, *sigmoïde* pour une classification binaire ou *softmax* pour plusieurs classes.

Pendant l'entraînement, les poids de ces couches sont ajustés automatiquement grâce à des méthodes comme la rétropropagation et la descente de gradient. Comme elles contiennent beaucoup de paramètres, ces couches peuvent facilement surapprendre, surtout si on a peu de données. Pour éviter cela, on utilise des techniques comme le dropout (désactiver temporairement certains neurones) ou la régularisation L2 (limiter la taille des poids).

3.3. Réseau de neurones profond: [48]

3.3.1. Structure d'un DNN:

Un réseau de neurones profond est une fonction composée de plusieurs couches successives, chacune calculant une transformation non linéaire de ses entrées.

Soit une entrée $x \in \mathbb{R}^d$

Le réseau est défini par une succession de couches L:

de couches L :

$$h^{(0)} = x \quad (\text{III-4})$$

Pour $l = 1, \dots, L$

$$h^{(l)} = f^{(l)} (W^{(l)} h^{(l-1)} + b^{(l)}) \quad (\text{III-5})$$

1. $h^{(l)}$ est le vecteur de sortie (activation) de la couche l .
2. $W^{(l)}$ est la matrice des poids pour la couche l .
3. $b^{(l)}$ est le vecteur de biais pour la couche l .
4. $f^{(l)}$ est la fonction d'activation non-linéaire appliquée couche par couche.

La sortie finale est souvent notée:

$$\hat{y} = h^{(L)} \quad (\text{III-6})$$

3.3.2. Fonction d'activation:

Les fonctions d'activation introduisent la non-linéarité nécessaire pour que le réseau apprenne des représentations complexes.

Les fonctions d'activation les plus utilisées sont :

1. Sigmoid :

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (\text{III-7})$$

2. Tanh (fonction tangente hyperbolique) :

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (\text{III-8})$$

3. ReLU (Rectified Linear Unit) :

$$\text{ReLU}(z) = \max(0, z) \quad (\text{III-9})$$

4. Leaky ReLU (variante de ReLU qui autorise un gradient faible pour $z < 0$) :

$$\text{LeakyReLU}(z) = \begin{cases} z & \text{Si } z > 0 \\ \alpha z & \text{sinon} \end{cases}$$

3.3.3. Fonction de perte (loss):

Le réseau est entraîné à minimiser une fonction de perte $\mathcal{L}(y, \hat{y})$, qui mesure l'écart entre la sortie réelle y et la prédiction $\hat{y}$.

Un exemple courant: l'erreur quadratique moyenne (MSE)

$$\mathcal{L}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{III-10})$$

3.3.4. Rétropropagation et gradient:

L'entraînement du DNN repose sur la rétropropagation du gradient, une application de la règle de la chaîne pour calculer efficacement les dérivées partielles de la fonction de perte par rapport aux paramètres $W^{(l)}$ et $b^{(l)}$

L'objectif est d'obtenir:

$$\frac{\partial \mathcal{L}}{\partial w^{(l)}}, \frac{\partial \mathcal{L}}{\partial b^{(l)}} \quad (\text{III-11})$$

Ces gradients sont calculés couche par couche, depuis la sortie vers l'entrée :

1. Soit $\delta^{(l)} = \frac{\partial \mathcal{L}}{\partial z^{(l)}}$, où $z^{(l)} = W^{(l)}h^{(l-1)} + b^{(l)}$ est la pré-activation.
2. Les gradients s'expriment alors :

$$\delta^{(l)} = (W^{(l+1)T} \delta^{(l+1)}) \odot f'(z^{(l)}) \quad (\text{III-12})$$

Avec $f'(z^{(l)})$ dérivée de la fonction d'activation, et $\odot$ le produit élément par élément.

Les gradients des paramètres sont:

$$\frac{\partial \mathcal{L}}{\partial W^{(l)}} = \delta^{(l)} h^{(l-1)T} \quad (\text{III-13})$$

$$\frac{\partial \mathcal{L}}{\partial b^{(l)}} = \delta^{(l)} \quad (\text{III-14})$$

3.3.5. Mise à jour des paramètres :

Les paramètres sont mis à jour par descente de gradient (ou variantes) avec un taux d'apprentissage η :

$$W^{(l)} \leftarrow W^{(l)} - \eta \frac{\partial \mathcal{L}}{\partial W^{(l)}} \quad (\text{III-15})$$

$$b^{(l)} \leftarrow b^{(l)} - \eta \frac{\partial \mathcal{L}}{\partial b^{(l)}} \quad (\text{III-16})$$




Figure I I I -6 Fonctionnement d'un neurone artificiel avec activation ReLU[49]

3.4.Architecture U-Net :

Le U-Net est un réseau de neurones convolutif proposé par **Ronneberger et al. en 2015**, spécialement conçu pour la segmentation d'images, notamment dans le domaine de l'imagerie médicale. Il se distingue par sa capacité à produire des segmentations précises même à partir d'un nombre limité d'images annotées. Son architecture en forme de « U », se compose de trois éléments principaux : une phase d'encodage, une phase de décodage, et des connexions latérales

(ou *skip connections*) qui assurent le transfert d'informations spatiales entre ces deux phases, contribuant ainsi à une meilleure précision des résultats.

Phase d'encodage (*contracting path*): Elle a pour but d'extraire les caractéristiques contextuelles globales de l'image. Cette étape repose sur une série de blocs composés de convolutions 3×3 avec activation ReLU, suivies d'un sous-échantillonnage par max pooling 2×2 . Ce processus réduit progressivement la résolution spatiale tout en augmentant la richesse des représentations sémantiques.

Phase de décodage (*expanding path*): Elle vise à reconstruire la résolution originale de l'image tout en affinant la localisation des structures pertinentes. Chaque étape commence par une up-convolution 2×2 (ou convolution transposée), suivie d'une concaténation avec les cartes de caractéristiques correspondantes issues de la phase d'encodage via les *skip connections*, permettant de préserver les détails fins. Ensuite, deux convolutions 3×3 avec activation ReLU sont appliquées pour affiner la prédiction. Enfin, une convolution 1×1 est utilisée en sortie afin d'ajuster le nombre de canaux aux classes cibles, générant ainsi une carte segmentée de même taille que l'image d'entrée, avec une annotation au niveau du pixel.[50]

3.5.U-Net avec mécanisme d'attention pour segmentation des images

biomédicales:

L'architecture U-Net avec mécanisme d'attention est un modèle de segmentation d'images biomédicales qui intègre des gates attentionnelles afin de focaliser l'analyse sur les régions les plus pertinentes de l'image (tumeurs). Cette attention permet au réseau de filtrer dynamiquement les informations extraites par les couches convolutives, en supprimant les régions non informatives et en renforçant les zones d'intérêt, comme les lésions ou structures anormales.

Concrètement, chaque gate attentionnelle reçoit en entrée une carte de caractéristiques $\mathbf{x}_l$ ainsi qu'un signal de guidage $\mathbf{g}$, et fonction une fonction d'attention additive définie par:

$$\alpha = \sigma_2(\mathbf{W}^T \cdot \text{ReLU}(\mathbf{W}_x \mathbf{x}_l + \mathbf{W}_g \mathbf{g} + \mathbf{b})) \quad (\text{III-17})$$

où $\mathbf{W}_x$, $\mathbf{W}_g$ et $\mathbf{b}$ sont des paramètres appris, ReLU est la fonction d'activation, et σ_2 une sigmoïde. Le masque d'attention α module ensuite $\mathbf{x}_l$ via une multiplication élément par

élément, afin de ne conserver que les informations pertinentes. Cette approche améliore la précision de la segmentation, particulièrement dans les cas de structures pathologiques subtiles ou denses, en rendant le modèle plus sélectif et robuste aux variations anatomiques.[51]

Nous avons utilisé l'architecture UNET avec un block d attention tel qu'illustré dans la figure suivante (Figure I I I 7)




Figure I I I -7 Architecture UNET avec un block d attention

4. Métriques d'évaluations[52]

4.1.Précision:

La precision est la proportion de pixels que le modèle a prédits comme appartenant à une structure d'intérêt (par exemple une tumeur ou un organe) et qui sont effectivement corrects. Autrement dit, elle mesure la capacité du modèle à éviter les fausses détections.

$$Précision = \frac{TP}{TP+FP} \quad (III-18)$$

TP (True Positives): nombre de pixels correctement identifiés comme appartenant à la région d'intérêt (ROI).

FP (False Positives): nombre de pixels incorrectement identifiés comme appartenant à la ROI (faux positifs).

4.2.Sensibilité:

La sensibilité (Sensitivity), aussi dénommée rappel (Recall) ou taux de vrais positifs (True Positive Rate), met l'accent sur l'aptitude à identifier les vrais positifs. En d'autres termes, elle évalue l'aptitude de modèle à détecter la fraction de pixels pertinents (comme une tumeur ou une lésion) identifiés correctement par le modèle par rapport au total de pixels vraiment positifs. La sensibilité est calculée par la formule suivante :

$$sensibilité = \frac{VP}{VP+FN} \quad (III-19)$$

VP (Vrai Positif) : les cas positifs correctement prédits,

FN (Faux Négatif) : les cas positifs mal classés comme négatifs.

Une sensibilité élevée indique que le modèle détecte bien les cas positifs.

4.3.Spécificité:

La spécificité (Spec), également appelée taux de vrais négatifs, évalue la capacité d'un modèle à identifier correctement les classes négatives, comme par exemple la classe de fond (background) dans une image.

Dans les tâches de segmentation d'images médicales (MIS), la spécificité indique la capacité du modèle à détecter correctement les zones de fond dans une image.

En raison de la grande proportion de pixels annotés comme fond par rapport à la région d'intérêt (ROI), il est courant et attendu que les valeurs de spécificité soient proches de 1. Ainsi, la spécificité est une métrique appropriée pour vérifier le bon fonctionnement général du modèle, mais elle est moins pertinente pour évaluer ses performances réelles sur la détection des régions médicalement importantes. La spécificité est calculée par la formule suivante :

$$Spécificité = \frac{VN}{VN+FP} \quad (III-20)$$

VN (Vrai Négatif) : les cas négatifs correctement prédits.

FP (Faux Positif) : les cas négatifs mal classés comme positifs.

Une spécificité élevée montre que le modèle évite bien les faux positifs. Cela est important lorsque les conséquences d'un faux positif sont significatives (ex. : traitement inutile).

4.4.Le coefficient de Dice

Le coefficient de similarité de Dice (**DSC**) est une mesure statistique utilisée pour évaluer la similarité entre deux ensembles binaires, en particulier dans le contexte de la segmentation d'images médicales. Il permet de comparer un masque de segmentation automatique à une vérité terrain (annotation manuelle) en quantifiant leur degré de recouvrement.

La formule du DSC est donnée par:

$$DSC = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (III-21)$$

A est l'ensemble des pixels prédits comme positifs,

B est l'ensemble des pixels réellement positifs.

Le DSC prend une valeur entre 0 (aucun chevauchement) et 1 (chevauchement parfait). Il est largement utilisé en segmentation d'images médicales car il est robuste aux déséquilibres de classes et tient compte à la fois des faux positifs et des faux négatifs.[53]

5. Conclusion:

Ce chapitre a établi les bases théoriques du travail en présentant les concepts clés de l'apprentissage profond et de la segmentation d'images médicales. Il a mis en avant la base de données Lung, le fonctionnement des réseaux de neurones (MLP, CNN), ainsi que l'architecture U-Net enrichie par un mécanisme d'attention. Enfin, les métriques d'évaluation comme le Dice, la précision, la sensibilité et la spécificité ont été exposées, préparant ainsi la transition vers la phase expérimentale du projet.

IV. Chapitre 04 : Résultats et discussions

1. Introduction :

Dans ce chapitre, nous présentons les résultats des modèles développés dans ce mémoire. Les deux modèles ont été testé sur la base de données Lung du Decatholon challenge Segmentation. Nous avons adoptés les métriques (Dice score, Spécificité, Snesibilité et Précision) pour évaluer les performances des deux modèles. Les résultats que nous avons obtenus se sont confrontés avec d'autres travaux ultérieurs sur la même base de données.

2. Résultats

Dans cette section, nous présontons les résultats obtenus en utilisant l'architecture UNET et l'architecture UNET avec mécanisme d'attention. Le modèle est entrainé sur l'ensemble des données d'apprentissage en ajustant les paramètres illustré dans le tableau suivant (Tableau IV-1)


HYPERPARAMETRE	VALEUR
LE PAS D'apprentissage	0,0001
Nombre d'époques	100
BATCH SIZE	16
Dimension des images	256×256

TableauIV-1: Hyperparamètres

Composant	Détail
GPU (carte graphique)	NVIDIA GeForce RTX 3050 (6 Go VRAM)
CPU (processeur)	Intel(R) Core(TM) i5-12400F (12CPUs)
RAM (mémoire vive)	16 Go
Système d'exploitation	Windows Professionnel 64 bits
Stockage (disque)	SSD NVMe
Logiciels	Python

TableauIV-2: caractéristiques de l'ordinateur utiliser

La figure suivante illustre les résultats de segmentation en comparaison avec le masque réel (annotation du médecin) (figure IV-1)




FigureIV-1: Les résultats de segmentation (Prediction) en comparaison avec le masque réel (Ground Truth: annotation du médecin)

Les résultats quantitatifs de chaque modèle sont présentés dans le tableau ci-dessous :

	DSC	SENSIBILITE	SPECIFICITE	PRECISION
Unet	0,85	0.87	0.99	0.92
Unet avec attention	0,88	0,87	0.99	0,95

TableauIV-3: Notre résultats de chaque modèle



FigureIV-2: Courbes de la perte d'entraînement et de la perte de validation

	Base de données	Dice	précision	Sensibilité
Prasad Dutande et al [54]	MSD	0.649	0,765	0,737
Fabian Isensee et al [55]	MSD	0.78	Non publier	Non publier
Notre travail (U-Net)	MSD	0,85	0.92	0.87
Notre travail (U-Net avec mécanisme d'attention)	MSD	0,88	0,95	0,87

TableauIV-5: comparaison résultats que nous avons obtenus avec d'autres travaux ultérieurs sur la même base de données

1. Discussion :

Les résultats obtenus dans le cadre de cette étude confirment l'efficacité de l'architecture U-Net enrichie par un mécanisme d'attention pour la segmentation automatique des lésions tumorales pulmonaires à partir d'images tomodensitométriques (CT thoraciques). L'approche proposée a été évaluée à la fois de manière quantitative à l'aide de métriques standards (Dice, sensibilité, spécificité, précision), et qualitative, par comparaison visuelle avec les annotations manuelles d'experts médicaux.

Sur le plan quantitatif, le modèle U-Net avec attention a surpassé le U-Net classique dans toutes les métriques principales. Le coefficient de Dice est passé de 0,85 à 0,88, reflétant une meilleure concordance globale entre les segmentations automatiques et les vérités terrain. La précision a également été significativement améliorée, atteignant 0,95 contre 0,92 pour le modèle de base, ce qui indique une diminution des faux positifs. La sensibilité est restée stable à 0,87, suggérant que le modèle maintient une bonne capacité à détecter la majorité des lésions. Enfin, la spécificité, très élevée dans les deux cas (0,99), montre que les zones saines sont correctement exclues de la segmentation.

Cette amélioration peut être attribuée à l'intégration du mécanisme d'attention, qui a permis au modèle de se concentrer plus efficacement sur les zones d'intérêt clinique, en ignorant les structures anatomiques non pertinentes. Cela a été particulièrement bénéfique pour la détection de nodules complexes, de petite taille, ou de faible contraste, qui constituent un défi majeur pour les modèles de segmentation traditionnels.

L'étude des courbes de perte d'entraînement et de validation (Figure VI-2) a mis en évidence une bonne convergence du modèle, sans apparition de surapprentissage. Dès la version 2, les courbes deviennent stables et parallèles, ce qui reflète un apprentissage maîtrisé. Cette stabilité est le résultat d'un réglage judicieux des hyperparamètres (Tableau VI-1), avec un taux d'apprentissage fixé à 0,0001, un nombre d'itérations limité à 100, une taille de lot de 16, et une dimension d'entrée des images de 128×128 pixels. De plus, le recours à des techniques d'augmentation de données (rotations, etc...) a permis d'accroître la robustesse du modèle et d'améliorer sa capacité de généralisation face à la diversité morphologique des lésions pulmonaires.

Du point de vue qualitatif, les résultats de segmentation présentés dans la (Figure VI-1) illustrent visuellement la capacité du modèle à reproduire fidèlement les contours des structures tumorales. Les contours prédits (en vert) présentent une forte correspondance avec les annotations manuelles (en bleu), même dans les cas de contours irréguliers ou flous. Cette performance visuelle est particulièrement remarquable dans les images du dernier rang, où les détections sont quasiment parfaites, confirmant l'impact du mécanisme d'attention sur la précision des bords segmentés.

L'efficacité globale du processus d'entraînement a également été soutenue par une infrastructure matérielle adaptée (Tableau VI-2), comprenant un processeur Intel Core i5-12400F (12 cœurs), une carte graphique NVIDIA GeForce RTX 3050 avec 6 Go de mémoire VRAM, 16 Go de RAM, et un disque SSD NVMe sous Windows 64 bits. Le tout a été exploité via un environnement Python, garantissant un bon équilibre entre temps de calcul, capacité mémoire et fluidité de traitement des données volumineuses.

Cependant, malgré ces résultats prometteurs, certaines limitations subsistent. Le modèle montre une sensibilité réduite dans le cas des nodules très petits ou peu contrastés, qui sont parfois partiellement segmentés ou confondus avec des artefacts pulmonaires. Pour pallier ces lacunes, il serait pertinent d'envisager une expansion de la base de données avec plus d'annotations manuelles, ainsi que l'introduction de méthodes de post-traitement. Ces derniers permettraient de renforcer la cohérence locale de la segmentation en prenant en compte les relations spatiales entre voxels, ce qui améliorerait la continuité des bords et réduirait les erreurs d'étiquetage.

En comparaison avec d'autres approches existantes reposant uniquement sur des réseaux de neurones convolutionnels classiques, la solution proposée se démarque par sa capacité à hiérarchiser les informations contextuelles et à cibler avec précision les régions pertinentes grâce au mécanisme d'attention. Cette combinaison confère au modèle une meilleure adaptabilité aux variations anatomiques et aux configurations pathologiques complexes.

Ces résultats confirment le potentiel du modèle pour une utilisation en contexte clinique, tout en ouvrant la voie à des travaux futurs pour surmonter les limitations identifiées.

2. Conclusion :

En conclusion, le modèle U-Net a prouvé sa pertinence pour la segmentation des poumons à partir d'images tomодensitométriques, en atteignant des scores de performance satisfaisants et des résultats visuellement cohérents. Ce travail met en évidence l'efficacité de cette architecture dans un contexte clinique, tout en soulignant des marges d'amélioration possibles. L'intégration d'approches plus avancées, comme les modèles 3D, les mécanismes d'attention, ou des stratégies de traitement post-prédiction, constitue une voie prometteuse pour affiner la précision du modèle et renforcer sa robustesse. Ces perspectives ouvrent la voie à une application future en pratique clinique, à condition de poursuivre l'optimisation et la validation sur des bases de données plus larges et diversifiées.

5. Conclusion Générale:

Ce travail s'inscrit pleinement dans la dynamique actuelle de l'intégration de l'intelligence artificielle, et plus spécifiquement de l'apprentissage profond, dans le domaine de l'imagerie médicale. En nous appuyant sur l'architecture U-Net, enrichie par des mécanismes d'attention, nous avons développé une méthode de segmentation automatique des tumeurs pulmonaires à partir d'images de tomodensitométrie (TDM), dans le but de fournir un outil fiable et efficace pour l'aide au diagnostic.

Les résultats expérimentaux obtenus, avec un coefficient de Dice de 0,88, attestent de la précision et de la pertinence du modèle proposé. L'introduction de mécanismes d'attention a significativement amélioré la capacité du réseau à se concentrer sur les régions d'intérêt, en particulier les zones tumorales, tout en réduisant les erreurs de segmentation. Cette approche permet ainsi d'optimiser la délimitation des lésions, ce qui est essentiel dans un contexte clinique.

Toutefois, malgré ces performances encourageantes, certaines limitations subsistent. La capacité du modèle à généraliser sur des données issues de sources variées, ou à détecter des lésions de petite taille, demeure un défi. Pour y remédier, des pistes d'amélioration peuvent être envisagées, telles que l'intégration d'architectures hybrides combinant réseaux convolutifs et transformeurs, ou encore la fusion multimodale d'informations provenant de différentes modalités d'imagerie médicale, afin de renforcer la richesse contextuelle de l'analyse.

Plus globalement, les travaux menés dans cette étude illustrent clairement le potentiel croissant de l'intelligence artificielle pour automatiser des tâches complexes en imagerie médicale. Ils confirment que l'IA ne se limite plus à un rôle exploratoire, mais peut désormais jouer un rôle opérationnel dans les pratiques cliniques, en venant appuyer le jugement des professionnels de santé.

En perspective, l'intégration de tels outils dans les flux de travail hospitaliers pourrait contribuer à réduire la charge cognitive et temporelle des radiologues, tout en améliorant la reproductibilité, la rapidité et la qualité des diagnostics. En particulier, ces technologies s'annoncent prometteuses pour la détection précoce des pathologies pulmonaires, condition essentielle à une prise en charge thérapeutique personnalisée, rapide et efficace.

Références:

1. Siegel, R.L., et al., *Cancer statistics, 2023*. CA: a cancer journal for clinicians, 2023. **73**(1): p. 17-48.
2. Howlader, N., et al., *The impact of underreported Veterans Affairs data on national cancer statistics: analysis using population-based SEER registries*. Journal of the National Cancer Institute, 2009. **101**(7): p. 533-536.
3. Litjens, G., et al., *A survey on deep learning in medical image analysis*. Medical image analysis, 2017. **42**: p. 60-88.
4. Sluimer, I., et al., *Computer analysis of computed tomography scans of the lung: a survey*. IEEE transactions on medical imaging, 2006. **25**(4): p. 385-405.
5. Taha, A.A. and A. Hanbury, *Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool*. BMC medical imaging, 2015. **15**: p. 1-28.
6. Warfield, S.K., K.H. Zou, and W.M. Wells, *Simultaneous truth and performance level estimation (STAPLE): an algorithm for the validation of image segmentation*. IEEE transactions on medical imaging, 2004. **23**(7): p. 903-921.
7. Dunn, E.F., K.R. Kozak, and J.S. Moody, *External beam radiotherapy for colon cancer: patterns of care*. International Journal of Radiation Oncology* Biology* Physics, 2010. **76**(5): p. 1420-1424.
8. Shen, D., G. Wu, and H.-I. Suk, *Deep learning in medical image analysis*. Annual review of biomedical engineering, 2017. **19**(1): p. 221-248.
9. Ronneberger, O., P. Fischer, and T. Brox. *U-net: Convolutional networks for biomedical image segmentation*. in *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III* 18. 2015. Springer.
10. Oktay, O., et al., *Attention u-net: Learning where to look for the pancreas*. arXiv preprint arXiv:1804.03999, 2018.
11. Zhang, Z., Q. Liu, and Y. Wang, *Road extraction by deep residual u-net*. IEEE Geoscience and Remote Sensing Letters, 2018. **15**(5): p. 749-753.
12. Riquet, M., *Anatomie du poumon humain*. Ency. Méd. Chir. Pneumo, 2012. **9**(3): p. 1-11.
13. Bessaguet, F. and A. Desmoulière, *Les poumons*. Actualités Pharmaceutiques, 2021. **60**(603): p. 55-59.
14. Drake, R.L., et al., *Gray's Anatomie - Les fondamentaux*. 2018: Elsevier Masson.
15. Hitier, M., et al., *Trachée: anatomie, physiologie, endoscopie et imagerie*. EMC Oto-rhino-laryngologie, 2013. **8**: p. 1-18.
16. Shields, T.W., et al., *General Thoracic Surgery*. 2011: Wolters Kluwer Health.
17. Relli, V., et al., *Abandoning the notion of non-small cell lung cancer*. Trends in molecular medicine, 2019. **25**(7): p. 585-594.
18. Succony, L., et al., *Adenocarcinoma spectrum lesions of the lung: Detection, pathology and treatment strategies*. Cancer treatment reviews, 2021. **99**: p. 102237.
19. Masson, F., X. Danguin, and P. Baudin, *Tomodensitométrie: principes, formation de l'image*, in *Scanner et Rayons X*. 2013, Elsevier. p. 119-174.
20. Ruiz-Cordero, R. and W.P. Devine, *Targeted therapy and checkpoint immunotherapy in lung cancer*. Surgical pathology clinics, 2020. **13**(1): p. 17-33.

21. Nemoto, M., et al., *Primary lung squamous cell carcinoma and its association with gastric metastasis: a case report and literature review*. Thoracic Cancer, 2020. **11**(6): p. 1708-1711.
22. Wagner, J., *Visualisation et post-traitement des images scannographiques: le logiciel Osirix*. 2007.
23. Hansell, D.M., et al., *Fleischner Society: glossary of terms for thoracic imaging*. Radiology, 2008. **246**(3): p. 697-722.
24. Régent, D., et al., *Production des rayons X en imagerie par projection et en scanographie*. EMC–Radiologie et imagerie médicale–principes et technique–radioprotection, 2013. **8**: p. 1-20.
25. Laziz, B., *Etude des appareils médicaux et application au scanner*. 2014, Université Mouloud Mammeri.
26. Marcelin, C., et al., *Percutaneous image-guided biopsies of small renal tumors: Current practice and perspectives*. Diagnostic and interventional imaging, 2017. **98**(9): p. 589-599.
27. Dos Santos, E.d.C., et al., *Adding positive airway pressure to mobilisation and respiratory techniques hastens pleural drainage: a randomised trial*. Journal of Physiotherapy, 2020. **66**(1): p. 19-26.
28. Barzakova, E., et al. *Detectability of Target Lesion During CT-Guided Tumor Ablations: Impact on Ablation Outcome*. in *RöFo-Fortschritte auf dem Gebiet der Röntgenstrahlen und der bildgebenden Verfahren*. 2022. Georg Thieme Verlag KG.
29. Bujold, A., et al. *Image-guided radiotherapy: has it influenced patient outcomes?* in *Seminars in radiation oncology*. 2012. Elsevier.
30. de Crevoisier, R., D. Kuban, and D. Lefkopoulos, *Radiothérapie guidée par tomodensitométrie associée à l'accélérateur linéaire dans la salle de traitement / Image-guided radiotherapy by in-room CT-linear accelerator combination*. Cancer/Radiothérapie, 2006. **10**(5): p. 245-251.
31. Singadkar, G., et al., *Deep deconvolutional residual network based automatic lung nodule segmentation*. Journal of digital imaging, 2020. **33**: p. 678-684.
32. Zhang, Q., et al., *Lung nodule diagnosis on 3D computed tomography images using deep convolutional neural networks*. Procedia Manufacturing, 2019. **39**: p. 363-370.
33. Aresta, G., et al., *iW-Net: an automatic and minimalistic interactive lung nodule segmentation deep network*. Scientific reports, 2019. **9**(1): p. 11591.
34. Ait El Bour, D. and B. Lebzar, *L'intelligence artificielle face aux entreprises marocaines, quels défis?* Revue Internationale d'Economie Numérique, 2020. **2**(1): p. 31-39.
35. Adon, R., et al., *Deep Learning: des usages contrastés Une contextualisation de l'ouvrage de Goodfellow, Bengio et Courville*. Statistique et Société, 2020. **8**(3): p. 55-108.
36. Shuvo, S.B., *An automated end-to-end deep learning-based framework for lung cancer diagnosis by detecting and classifying the lung nodules*. arXiv preprint arXiv:2305.00046, 2023.
37. Jocher, G., et al., *ultralytics/yolov5: v7. 0-yolov5 sota realtime instance segmentation*. Zenodo, 2022.
38. Dosovitskiy, A., et al., *An image is worth 16x16 words: Transformers for image recognition at scale*. arXiv preprint arXiv:2010.11929, 2020.

39. Huang, J., et al., *Research on Segmentation Technology in Lung Cancer Radiotherapy Based on Deep Learning*. Current Medical Imaging Reviews, 2023. **19**(11): p. 1231-1244.
40. Pang, S., et al., *CTumorGAN: a unified framework for automatic computed tomography tumor segmentation*. European journal of nuclear medicine and molecular imaging, 2020. **47**: p. 2248-2268.
41. Serj, M.F., et al., *A deep convolutional neural network for lung cancer diagnostic*. arXiv preprint arXiv:1804.08170, 2018.
42. Riaz, Z., et al., *Lung Tumor Image Segmentation from Computer Tomography Images Using MobileNetV2 and Transfer Learning*. Bioengineering 2023, *10*, 981. 2023.
43. Liu, M., et al. *Segmentation of lung nodule in CT images based on mask R-CNN*. in *2018 9th International Conference on Awareness Science and Technology (iCAST)*. 2018. IEEE.
44. Kalaivani, N., et al. *Deep learning based lung cancer detection and classification*. in *IOP conference series: materials science and engineering*. 2020. IOP Publishing.
45. Antonelli, M., et al., *The Medical Segmentation Decathlon*. Nature Communications, 2022. **13**(1): p. 4128.
46. Antonelli, M., et al., *The medical segmentation decathlon*. Nature communications, 2022. **13**(1): p. 4128.
47. Yamashita, R., et al., *Convolutional neural networks: an overview and application in radiology*. Insights into imaging, 2018. **9**: p. 611-629.
48. Goodfellow, I., Y. Bengio, and A. Courville, *Deep Learning*. 2016: MIT Press.
49. Georgevici, A.I. and M. Terblanche, *Neural networks and deep learning: a brief introduction*. Intensive Care Medicine, 2019. **45**(5): p. 712-714.
50. Siddique, N., et al., *U-Net and its variants for medical image segmentation: theory and applications*. arXiv preprint arXiv:2011.01118, 2020.
51. Slimani, F.A.A., *Segmentation et classification des pathologies pulmonaires par apprentissage profond: intégration de la transformée en ondelettes discrètes et des mécanismes d'attention*. 2025.
52. Müller, D., I. Soto-Rey, and F. Kramer, *Towards a guideline for evaluation metrics in medical image segmentation*. BMC Research Notes, 2022. **15**(1): p. 210.
53. Watanabe, Y. and R. Akramova, *Radiomics as a measure superior to the Dice similarity coefficient for tumor segmentation performance evaluation*. arXiv preprint arXiv:2310.20039, 2023.
54. Dutande, P., U. Baid, and S. Talbar, *Deep residual separable convolutional neural network for lung tumor segmentation*. Computers in biology and medicine, 2022. **141**: p. 105161.
55. Isensee, F., et al., *nnu-net: Self-adapting framework for u-net-based medical image segmentation*. arXiv preprint arXiv:1809.10486, 2018.

Résumé:

Cette étude explore l'utilisation de l'apprentissage profond pour la segmentation automatique des tumeurs pulmonaires à partir d'images tomodensitométriques (TDM). Nous proposons une architecture basée sur U-Net, enrichie d'un mécanisme d'attention, afin d'améliorer la précision de la détection des lésions tumorales. Le modèle a été entraîné et évalué sur la base de données Medical Segmentation Decathlon (MSD), comprenant des images TDM thoraciques annotées.

Nos résultats démontrent une performance élevée, avec un coefficient de Dice de 0,88, une sensibilité de 0,87 et une précision de 0,92, surpassant plusieurs approches existantes. L'intégration d'un mécanisme d'attention permet au modèle de mieux cibler les régions tumorales, réduisant ainsi les faux positifs et améliorant la segmentation des lésions de petite taille.

Cependant, certaines limitations persistent, notamment la complexité computationnelle des modèles 3D et la nécessité d'une validation sur des ensembles de données plus variés. Les perspectives futures incluent l'optimisation des architectures 3D, l'intégration de réseaux hybrides (CNN + Transformers) et l'application en temps réel pour la radiothérapie guidée par l'IA.

Cette recherche contribue à l'avancement des outils d'aide au diagnostic en oncologie thoracique, offrant une solution prometteuse pour une détection précoce et une planification thérapeutique plus précise.

This study explores the use of deep learning techniques for the automatic segmentation of lung tumors from computed tomography (CT) images. We propose an architecture based on U-Net, enhanced with an attention mechanism, in order to improve the accuracy of lesion detection. The model was trained and evaluated on the Medical Segmentation Decathlon (MSD) dataset, which includes annotated thoracic CT scans.

Our results demonstrate high performance, achieving a Dice coefficient of 0.88, a sensitivity of 0.87, and a precision of 0.92, surpassing several existing approaches. The integration of an attention mechanism enables the model to more effectively target tumor regions, reducing false positives and enhancing the segmentation of small lesions.

However, certain limitations remain, notably the computational complexity of 3D models and the need for validation on more diverse datasets. Future directions include optimizing 3D architectures, integrating hybrid networks (CNN + Transformers), and enabling real-time applications for AI-guided radiotherapy.

This research contributes to the advancement of decision-support tools in thoracic oncology, offering a promising solution for early detection and more accurate therapeutic planning.

تستكشف هذه الدراسة استخدام تقنيات التعلم العميق في التجزئة التلقائية للأورام الرئوية انطلاقاً من صور الأشعة المقطعية (TDM). نقترح بنية معمارية تعتمد على نموذج U-Net مدعّم بآلية الانتباه، بهدف تحسين دقة الكشف عن الآفات الورمية. تم تدريب النموذج وتقييمه على قاعدة بيانات (Medical Segmentation Decathlon (MSD، التي تتضمن صوراً مقطعية للصدر مشروحة.

أظهرت نتائجنا أداءً مرتفعاً، حيث بلغ معامل Dice حوالي 0.88، والحساسية 0.87، والدقة 0.92، متفوقاً بذلك على العديد من الأساليب الحالية. إن دمج آلية الانتباه سمح للنموذج بالتركيز بشكل أدق على المناطق الورمية، مما ساهم في تقليل الإيجابيات الكاذبة وتحسين تجزئة الأورام صغيرة الحجم.

ومع ذلك، لا تزال بعض التحديات قائمة، مثل التعقيد الحسابي للنماذج ثلاثية الأبعاد، والحاجة إلى التحقق من الصحة على مجموعات بيانات أكثر تنوعاً. وتشمل آفاق العمل المستقبلي تحسين البنى ثلاثية الأبعاد، ودمج الشبكات الهجينة (CNN+ Transformers)، وتطبيق النموذج في الزمن الحقيقي ضمن سياق العلاج الإشعاعي الموجه بالذكاء الاصطناعي.

تُعد هذه الدراسة مساهمة واعدة في تطوير أدوات المساعدة على التشخيص في طب الأورام الصدري، مما يوفر حلاً فعالاً للكشف المبكر والتخطيط العلاجي الدقيق.