

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة

التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد -

تلمس -

Université Aboubakr Belkaïd – Tlemcen –  
Faculté de TECHNOLOGIE



## MEMOIRE

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

**En** : Génie biomédical

**Spécialité** : Imagerie médicale

**Par** : HECINI MOHAMMED

### Sujet

**Exploitation de la Segmentation d'Images en Échographie Mammaire  
dans le Diagnostic du Cancer du Sein**

Soutenu publiquement, le 06/10/2025, devant le jury composé de :

M TALEB TARIQ	MCB	Université de Tlemcen	Président
Mme BENSAMAIL ILHEM	MCB	Université de Tlemcen	Examinateur
M Youbi ridha	MAA	Université de Tlemcen	Encadrant

# بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

قال الله تعالى: "يَرْفَعِ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ"

الآية " 11 المجادلة"

## **Remerciements**

*Avant tout, je tiens à remercier Allah Tout-Puissant pour m'avoir accordé la santé, la patience et la force nécessaires pour mener à bien ce travail et franchir cette étape importante de mon parcours universitaire.*

*Je souhaite exprimer toute ma gratitude à mon encadrant, Monsieur le Professeur Youbi Ridha, pour sa bienveillance, ses précieux conseils et sa disponibilité tout au long de l'élaboration de ce mémoire. Son accompagnement attentif et ses orientations éclairées ont grandement contribué à la réussite de ce projet.*

*J'adresse également mes sincères remerciements aux membres du jury, Monsieur Taleb Tariq et Madame Bensamail Ilhem, pour l'honneur qu'ils me font en acceptant d'évaluer ce travail et pour leurs remarques constructives, qui ont permis d'enrichir sa qualité scientifique.*

*Je tiens à remercier du fond du cœur mes parents, pour leur soutien constant, leurs sacrifices et la confiance qu'ils ont toujours placée en moi. Rien de tout cela n'aurait été possible sans leur amour et leurs encouragements.*

*Ma reconnaissance va aussi à toute ma famille pour leur présence réconfortante, et plus particulièrement à mes grands-parents, dont les prières et les mots d'encouragement m'ont accompagné tout au long de ce parcours.*

*Enfin, je souhaite remercier chaleureusement l'ensemble de mes professeurs pour leur dévouement, leur passion et la qualité de leur enseignement. Leur accompagnement tout au long de ma formation a été essentiel à mon développement et à l'aboutissement de ce mémoire.*

# Table des matières

CHAPITER I : Introduction au Cancer du Sein et à la Segmentation d'Images .....	13
<b>I.1 Introduction de chapitre 1 :</b> .....	2
<b>I.2 Anatomie du cancer du sein :</b> .....	4
<b>I.2.1 Explications pour l'anatomie cancer de sein</b> .....	4
<b>I.3 Vue d'ensemble sur le cancer du sein</b> .....	5
<b>I.3.1 Prévalence et importance du cancer du sein à l'échelle mondiale :</b> .....	5
<b>I.3.2 Prévalence et importance du cancer du sein en Algérie :</b> .....	6
<b>I.4 Les différents types et stades du cancer du sein :</b> .....	7
<b>I.4.1 Classification Histologique (Origine des Cellules)</b> .....	7
<b>I.4.2 Classification Moléculaire</b> .....	8
<b>I.4.3 Stades cliniques (classification TNM)</b> .....	9
<b>I.5 l'importance de la détection et du diagnostic précoces :</b> .....	10
<b>I.6 L'Imagerie Médicale dans le Diagnostic du Cancer du Sein :</b> .....	11
<b>I.6.1 Examen mammographique :</b> .....	11
<b>I.6.2 Examen échographique :</b> .....	13
<b>I.6.3 L'IRM mammaire :</b> .....	15
<b>I.6.4 La scintigraphie :</b> .....	15
<b>I.6.5 RESULTATS/ ICONOGRAPHIES :</b> .....	17
<b>I.7 La Segmentation d'Images: Fondements et Importance :</b> .....	18
<b>I.7.1 Définition de la segmentation en imagerie médicale :</b> .....	18
<b>I.7.2 Objectif de la segmentation :</b> .....	18
<b>I.7.3 L'importance d'une segmentation précise dans l'analyse d'images médicales :</b> <b>Application au cancer du sein :</b> .....	18
<b>I.7.4 Défis de la Segmentation des Images Mammaires en Oncologie :</b> .....	19
<b>I.8 Structure Proposée pour les Chapitres</b> .....	20
I.9 Conclusion de chapitre 1 : .....	20
Chapiter II : le rôle de l'informatique dans l'analyse des images médicales et L état de l'art ....	21
<b>II.1 Introduction de chapitre 2 :</b> .....	22
<b>II.2 Fondamentaux du Traitement d'Images Numériques en Médecine :</b> .....	23
<b>II.2.1 Prétraitement : Amélioration de la qualité des images</b> .....	23
<b>II.2.2 Segmentation :</b> .....	26
<b>II.2.3 Caractérisation et Quantification : Mesure et description des éléments segmentés :</b> ..	28

II.2.4 Enregistrement (Registration) : Aligement d'Images pour Comparaison ou Fusion	28
II.3 L'Apport de l'Intelligence Artificielle et de l'Apprentissage Profond :	29
II.3.1 Architecture et Composants Clés des CNN	29
II.3.2 Avantages des CNN pour la Segmentation d'Images :	30
II.3.3 Architectures CNN pour la Segmentation d'Images Médicales :	31
II.4 l'État de l'Art : L'Impact des CNNs et de U-Net en Échographie Mammaire :	37
II.5 Conclusion de chapitre 2 :	45
CHAPITER III : Méthodologie et Implémentation	46
III.1 Introduction de chapitre 3 :	47
III.2 l'explication de l'algorithme pour les méthodes classiques de la segmentation :	50
III.3 Expliquer les détails de la technologie d'apprentissage profond	57
III.3.1 Détailler le choix et la description de l'architecture d'apprentissage profond :	57
III.3.2 Description de l'architecture spécifique:	57
III.3.3 Description du base de Données (Dataset) :	60
III.3.4 Pré-traitement des Données :	62
III.3.5 Paramètres d'entraînement du Modèle :	62
III.3.6 modèle évaluation:	63
III.3.7 Critères d'arrêt et validation :	64
III.4 Métriques d'évaluation pour la segmentation d'images médicales :	64
III.4.1 Discussion sur les métriques de performance en segmentation d'images médicales.	64
III.5 Conclusion du Chapitre3 :	67
CHAPITER IV : Résultats et Discussion	68
IV.1 Introduction de chapitre 4 :	69
IV.2 Résultats obtenus grâce au modèle	70
IV.2.1 Discussion des résultats pour les courbes	71
IV.3 Présentation visuelle des résultats :	73
IV.3.1 Discussion des exemples :	80
IV.4 Présentation Détaillée des Résultats Numériques :	82
IV.5 Discussion pour les résultats numériques :	86
IV.5.1 Comparaison entre l'apprentissage profond (cnn) et les méthodes classiques :	86
IV.5.2 Comparaison entre notre modèle de l'apprentissage profond (cnn) et l'état de l'art :	89

<b>IV.5.3 Analyse des caractéristiques de les tumeurs :</b> .....	91
<b>IV.5.4 Analyse des Caractéristiques Morphologiques et Radiométriques des Tumeurs</b> .....	93
<b>IV.6 Discussion des Défis et Limitations de Notre Modèle:</b> .....	95
<b>IV.7 Perspectives et Travaux Futurs :</b> .....	96
<b>IV.8 conclusion de chapitre 4 :</b> .....	98
<b>Conclusion Générale :</b> .....	99

## liste des figures

Figure 1 : Anatomie du sein et localisation d'une tumeur maligne .....	4
Figure 2 : Image de machine de mammographie.....	13
figure 3 : présenter la machine de l'échographe.....	14
figure 4 : présenter la machine de l'IRM.....	15
figure 5 : présenter la machine de la scintigraphie.....	16
figure 6 : présenter les images pour la diagnostic de cancer de sein à partir de l'échographie.....	17
figure 7 : présentation pour l'image original après le Prétraitement.....	25
figure 8 : Schéma d'un CNN appliqué à la segmentation des images échographiques du cancer du sein.....	30
figure 9 : Exemple de segmentation sémantique avec U-Net.....	32
figure 10: Exemple de segmentation sémantique avec Mask R-CNN .....	33
figure 11 : Exemple de segmentation sémantique avec SegNet.....	35
figure 12 : Diagramme de Segmentation des Lésions Mammaires par les méthodes classiques.....	48
figure 13 : Diagramme de Segmentation des Lésions Mammaires par la méthode cnn.....	49
figure 14 : présentation pour les étapes pour la segmentation par croissant des régions.....	55
figure 15 : a présentation pour les étapes pour la segmentation par K-means.....	56
figure 16: la présentation pour les étapes pour la segmentation par contour actif .....	56
figure 17 : Schéma de l'architecture U-Net modifiée utilisée pour la segmentation des tumeurs mammaires .....	59

figure 18 : les Courbes d'entraînement.....	70
figure 19 : courbe ROC.....	71
figure 20 : la Matrice de Confusion.....	71
figure 21: présenter les étapes de la pré-traitement .....	78

## la liste des tableaux

Tableau 1 : les différentes classifications stades pour le cancer du sein.....	9
Tableau 2 : Comparaison des méthodes classiques de segmentation d'images médicales...	28
Tableau 3 : comparatif des architectures adaptées à l'analyse d'images médicales .....	36
Tableau 4 : Résumé des caractéristiques de l'architecture U-Net modifiée.....	58
Tableau 5 : résultats d'entraînement.....	72
Tableau 6 : résultats de segmentation de croissance de région.....	73
Tableau 7 : résultats de segmentation k-means.....	75
Tableau 8 : Résultats de la segmentation par la méthode de contour actif.....	77
Tableau 9 : résultats de segmentation de cnn(u-net).....	79
Tableau 10 : résultats Métrique de performance pour les images tumeur bénigne.....	82
Tableau 11 : résultats Métrique de performance pour les images tumeur malignant.....	84
Tableau 12 : Résultats des caractéristiques de la tumeur pour les images.....	91

## **Résumé :**

Le diagnostic du cancer du sein repose aujourd'hui sur l'interprétation des images échographiques par des radiologues, souvent aidés par des systèmes d'aide à la décision. Cependant, la performance de ces systèmes dépend encore fortement de l'expérience humaine, notamment pour la sélection manuelle des régions d'intérêt. Pour réduire cette dépendance et améliorer la précision du diagnostic, nous avons développé dans ce projet un système automatisé de segmentation des tumeurs mammaires basé sur des réseaux de neurones convolutifs profonds (CNN), et plus particulièrement sur l'architecture U-Net.

Notre travail s'est concentré sur la segmentation sémantique des lésions cancéreuses à partir d'images échographiques, en comparant les performances du modèle U-Net à celles de méthodes classiques telles que le Région Growing, le k-mans et les Contours Actifs. Le modèle U-Net a été entraîné sur un ensemble d'images échographiques annotées (437 bénignes et 210 malignes), et évalué selon plusieurs métriques (Dicey, Jaccard, Accourcie, F1-Score). Les résultats obtenus montrent une nette supériorité du U-Net avec des scores atteignant 0.98 pour le Dicey et 0.97 pour l'indice de Jaccard, surpassant largement les performances inconstantes des méthodes classiques, notamment dans le cas des tumeurs malignes à bords irréguliers.

En plus de la segmentation, des caractéristiques morphologiques telles que l'aire, la circularité, La solidité ou l'excentricité ont été extraites, offrant une base pour une classification future des tumeurs. Ces résultats démontrent la robustesse de l'approche proposée et ouvrent des perspectives intéressantes pour l'intégration clinique, notamment en tant qu'outil d'aide au diagnostic ou au suivi évolutif des lésions mammaires.

**mots-clés :** Cancer du sein Diagnostic, Échographie mammaire, Segmentation des tumeurs

Réseaux de neurones convolutifs (CNN), U-Net (architecture) Apprentissage profond (Deep Learning) Métriques d'évaluation (Dicey, Jaccard, Précision, F1-Score)

Tumeurs bénignes, Tumeurs malignes, Caractéristiques morphologiques, Aide au diagnostic

## Abstract:

Breast cancer diagnosis currently relies on the interpretation of ultrasound images by radiologists, often aided by decision support systems. However, the performance of these systems still relies heavily on human experience, particularly for the manual selection of regions of interest. To reduce this dependency and improve diagnostic accuracy, in this project we developed an automated breast tumor segmentation system based on deep convolutional neural networks (CNNs), and more specifically on the U-Net architecture.

Our work focused on the semantic segmentation of cancerous lesions from ultrasound images, comparing the performance of the U-Net model with that of conventional methods such as Region Growing, k-Mans, and Active Contours. The U-Net model was trained on a set of annotated ultrasound images (437 benign and 210 malignant) and evaluated using several metrics (Dicey, Jaccard, Shortened, F1-Score). The results obtained show a clear superiority of the U-Net, with scores reaching 0.98 for the Dicey index and 0.97 for the Jaccard index, significantly surpassing the inconsistent performance of conventional methods, particularly in the case of malignant tumors with irregular borders.

In addition to segmentation, morphological characteristics such as area, circularity, solidity, and eccentricity were extracted, providing a basis for future tumor classification. These results demonstrate the robustness of the proposed approach and open up interesting prospects for clinical integration, particularly as a tool to aid in the diagnosis or evolutionary monitoring of breast lesions.

**Keywords:** Breast Cancer Diagnosis, Breast Ultrasound, Tumor Segmentation

Convolutional Neural Networks (CNN), U-Net (architecture), Deep Learning, Evaluation Metrics (Dicey, Jaccard, Accuracy, F1-Score)

Benign Tumors, Malignant Tumors, Morphological Features, Diagnostic Assistance

ملخص:

يعتمد تشخيص سرطان الثدي حاليًا على تفسير صور الموجات فوق الصوتية من قبل أخصائي الأشعة، غالبًا بمساعدة أنظمة دعم القرار. ومع ذلك، لا يزال أداء هذه الأنظمة يعتمد بشكل كبير على الخبرة البشرية، وخاصةً في الاختيار اليدوي للمناطق محل الاهتمام. لتقليل هذا الاعتماد وتحسين دقة التشخيص، قمنا في هذا المشروع بتطوير نظام آلي لتجزئة أورام U-Net، وبشكل أكثر تحديدًا على بنية (CNNs) الثدي يعتمد على الشبكات العصبية التلافيفية العميقة

بأداء U-Net ركز عملنا على التجزئة الدلالية للأفات السرطانية من صور الموجات فوق الصوتية، ومقارنة أداء نموذج على مجموعة U-Net تم تدريب نموذج Active Contours و Region Growing و k-Mans الطرق التقليدية مثل من صور الموجات فوق الصوتية المُعلّقة (437 صورة حميدة و210 صور خبيثة) وتم تقييمها باستخدام عدة مقاييس ، حيث بلغت U-Net تُظهر النتائج المُحصّلة تفوقًا واضحًا لشبكة (Dicey و Jaccard و Shortened و F1-Score). الدرجات 0.98 لمؤشر دائسي و0.97 لمؤشر جاك أرد، متجاوزةً بشكل ملحوظ الأداء غير المتسق للطرق التقليدية، لا سيما في حالة الأورام الخبيثة ذات الحدود غير المنتظمة. بالإضافة إلى التجزئة، تم استخلاص خصائص مورفولوجية مثل المساحة، والدائرية، والصلابة، واللامركزية، مما يوفر أساسًا لتصنيف الأورام مستقبلاً. تُظهر هذه النتائج متانة النهج المُقترح وتفتح آفاقًا واعدة للتكامل السريري، لا سيما كأداة للمساعدة في تشخيص آفات الثدي أو رصد تطورها

**الكلمات المفتاحية:** سرطان الثدي؛ تشخيص سرطان الثدي؛ تجزئة الأورام بالموجات فوق الصوتية باستخدام الشبكات ؛ F1 ؛ الدقة؛ درجة Jaccard؛ Dice ؛ التعلم العميق؛ مقاييس التقييم؛ U-Net ؛ بنية شبكة (CNN) العصبية التلافيفية الأورام الحميدة؛ الأورام الخبيثة؛ السمات المورفولوجية؛ المساعدة التشخيصية

---

---

# CHAPITRE I : Introduction au Cancer du Sein et à la Segmentation d'Images

---

---

### I.1 Introduction :

Le cancer du sein représente un défi majeur de santé publique à l'échelle mondiale, étant le type de cancer le plus fréquemment diagnostiqué chez les femmes et l'une des principales causes de mortalité liée au cancer. Il touche des millions de femmes chaque année. Selon l'Organisation mondiale de la santé (OMS), plus de 2,3 millions de nouveaux cas sont diagnostiqués chaque année dans le monde, soulignant l'urgence de mettre en place des stratégies efficaces de prévention, de dépistage et de traitement.

En Algérie, le cancer du sein constitue également la forme de cancer la plus fréquente chez la femme. Les statistiques nationales montrent une augmentation constante du nombre de cas, avec des diagnostics souvent tardifs en raison d'un accès limité au dépistage, d'un manque de sensibilisation et de barrières socioculturelles. Cette situation accentue l'importance cruciale d'un diagnostic précoce, permettant d'améliorer significativement les chances de survie et la qualité de vie des patientes.

Le cancer du sein se présente sous différentes formes histologiques, parmi lesquelles les plus courantes sont le carcinome canalaire infiltrant et le carcinome lobulaire. En fonction de leur évolution, ces tumeurs sont classées en plusieurs stades (de 0 à IV), qui définissent l'étendue de la maladie, la taille de la tumeur et la présence ou non de métastases.

La détection précoce reste l'un des moyens les plus efficaces pour réduire la mortalité. Plus une tumeur est identifiée à un stade précoce, plus le traitement est simple, moins invasif, et plus les chances de guérison sont élevées. C'est pourquoi les campagnes de dépistage, ainsi que le développement de techniques de diagnostic fiables, sont devenus des priorités majeures en santé publique.

Parmi les outils de diagnostic, l'imagerie médicale joue un rôle central. Elle permet de visualiser la structure interne du sein, de repérer des anomalies et d'orienter les décisions cliniques. L'échographie mammaire, en particulier, est une modalité non invasive, accessible et bien adaptée à l'analyse des tissus denses, ce qui en fait un outil privilégié dans de nombreux contextes cliniques.

Cependant, l'interprétation des images échographiques peut s'avérer difficile, notamment en raison du bruit de speckle et des bords flous. C'est dans ce contexte que la segmentation des


## **Chapitre I Introduction au Cancer du Sein et à la Segmentation d'Images**

Désions tumorales devient essentielle. La segmentation d'images est une technique qui permet d'isoler automatiquement les régions d'intérêt (telles qu'une tumeur) dans une image médicale. Elle constitue ainsi une étape clé pour l'extraction de caractéristiques morphologiques et pour l'aide au diagnostic médical.

Face à ces défis d'interprétation et à la nécessité d'un diagnostic précoce fiable, notre projet s'inscrit dans une démarche de recherche de solutions innovantes visant à améliorer l'efficacité de la détection et la caractérisation des lésions mammaires par l'exploitation des techniques de traitement d'images échographiques.

Ce chapitre posera les bases nécessaires à la compréhension de notre travail, en explorant d'abord le cancer du sein, puis les techniques d'imagerie, et enfin le concept de segmentation d'images médicales.

## I.2 Anatomie du cancer du sein :



**Figure 1 : Anatomie du sein et localisation d'une tumeur maligne**

### I.2.1 Explications pour l'anatomie cancer de sein

Cette illustration représente une coupe anatomique du sein humain, détaillant ses composants principaux tels que la paroi thoracique, les muscles (intercostal et pectoral), les côtes, les vaisseaux sanguins, le tissu adipeux, les canaux mammaires et le mamelon. Au cœur de cette structure, une tumeur maligne est clairement visible, soulignant sa localisation typique au sein des tissus mammaires. Cette figure est essentielle pour visualiser l'environnement anatomique où le cancer du sein se développe, aidant ainsi à comprendre les implications pour le diagnostic par imagerie et les stratégies de traitement.

### **I.3 Vue d'ensemble sur le cancer du sein:**

#### **I.3.1 Prévalence et importance du cancer du sein à l'échelle mondiale :**

Le cancer du sein représente aujourd'hui l'un des principaux enjeux de santé publique dans le monde. Il s'agit du cancer le plus fréquent chez la femme et de la première cause de mortalité par cancer dans cette population. En 2020, environ 2,3 millions de nouveaux cas ont été recensés à l'échelle mondiale, entraînant près de 685 000 décès, ce qui correspond à environ 25 % de l'ensemble des cancers féminins [1].

Des disparités géographiques notables sont observées. Dans les pays à revenu élevé, l'incidence est particulièrement importante — atteignant par exemple près de 90 cas pour 100 000 femmes en Europe —, ce qui est souvent attribué au vieillissement démographique, à l'urbanisation et à une exposition accrue à certains facteurs hormonaux [2]. À l'inverse, les pays à revenu faible et intermédiaire présentent une mortalité proportionnellement plus élevée, représentant près de 60 % des décès mondiaux, principalement en raison de diagnostics tardifs, d'un dépistage limité et d'un accès restreint aux traitements [3].

Les facteurs de risque associés au cancer du sein sont multiples. Sur le plan génétique, les mutations des gènes BRCA1 et BRCA2 sont impliquées dans environ 5 à 10 % des cas, augmentant considérablement le risque de développer la maladie (Kuchenbaecker et al., 2017). En parallèle, des facteurs liés au mode de vie influencent également ce risque, tels que l'obésité après la ménopause, qui accroît le risque de 20 à 40 %, ou encore la consommation régulière d'alcool, dont plus d'un verre par jour augmente le risque relatif de 7 à 10 % [4,5].

L'impact socio-économique du cancer du sein est particulièrement significatif. Le coût mondial annuel lié à sa prise en charge est estimé à environ 20 milliards de dollars, un chiffre qui continue d'augmenter avec l'incidence croissante de la maladie [6]. Les inégalités d'accès aux soins accentuent ce fardeau, avec un taux de survie à 5 ans supérieur à 90 % dans les pays à revenu élevé, contre moins de 40 % dans certaines régions d'Afrique subsaharienne [7].

Face à cette réalité, plusieurs stratégies de prévention et de dépistage ont démontré leur efficacité. Le dépistage organisé par mammographie permet de réduire la mortalité de 20 à 30 % [8], tandis que la promotion de modes de vie sains, associée à la sensibilisation de la population féminine, constitue un levier essentiel pour limiter l'incidence future de la maladie [9].

### I.3.2 Prévalence et importance du cancer du sein en Algérie :

En Algérie, le cancer du sein demeure le cancer le plus fréquent chez la femme, représentant 42,7 % de l'ensemble des cancers féminins diagnostiqués [10]. Chaque année, près de 15 000 nouveaux cas sont recensés, ce qui correspond à un taux d'incidence standardisé d'environ 45 cas pour 100 000 femmes [11,12]. La mortalité annuelle est estimée à environ 3 500 décès (OMS, 2022), et le taux de survie à 5 ans reste limité à 68 %, bien inférieur à celui observé dans les pays développés, où il dépasse généralement 90 %, principalement en raison d'un diagnostic souvent tardif [13].

Un aspect préoccupant du cancer du sein en Algérie est son âge de survenue plus précoce : environ 30 % des cas sont diagnostiqués avant 40 ans, contre seulement 5 % en Europe [14]. Parmi les facteurs de risque spécifiques, une proportion notable de patientes présente des mutations génétiques de type BRCA1 et BRCA2, particulièrement dans les formes précoces [15]. À cela s'ajoutent des déterminants comportementaux tels que la sédentarité, qui touche environ 60 % des femmes algériennes (OMS, 2021), ainsi que l'obésité, présente chez 35 % des femmes âgées de 35 à 60 ans (Ministère de la Santé, 2020).

L'accès aux soins constitue un défi majeur, marqué par un diagnostic souvent tardif : environ 60 % des cas sont identifiés aux stades II ou III [16]. Ces retards sont accentués par des disparités régionales, particulièrement dans les zones rurales, où le manque de spécialistes et d'équipements en oncologie limite la prise en charge rapide et efficace.

Afin de répondre à cette problématique, l'Algérie a mis en place une stratégie nationale de lutte contre le cancer, intégrant un programme de dépistage organisé depuis 2016, offrant une mammographie gratuite aux femmes âgées de 40 à 69 ans. Des campagnes de sensibilisation, notamment l'initiative « Octobre Rose », ont également contribué à améliorer l'information du public et à promouvoir la détection précoce. Par ailleurs, le renforcement des infrastructures sanitaires, avec la création de 12 centres anticancéreux publics, ainsi que l'intégration de thérapies ciblées comme le trastuzumab dans le panier de soins, représentent des avancées notables dans la prise en charge du cancer du sein en Algérie [17].

### I.4 Les différents types et stades du cancer du sein :

#### I.4.1 Classification Histologique (Origine des Cellules)

La classification histologique du cancer du sein repose sur l'origine cellulaire et les caractéristiques morphologiques des tumeurs. Le carcinome canalaire constitue la forme la plus fréquente, représentant environ 70 à 80 % des cas [18]. Il se subdivise principalement en deux entités : le carcinome canalaire in situ (DCIS), une lésion non invasive confinée aux canaux galactophores [19], et le carcinome canalaire infiltrant (IDC), qui correspond à une forme invasive caractérisée par sa capacité à franchir la membrane basale et à s'étendre aux tissus adjacents [18].

Le carcinome lobulaire est la deuxième forme la plus courante, diagnostiquée dans environ 10 à 15 % des cas [20]. Ce type inclut le carcinome lobulaire in situ (LCIS), considéré comme une lésion précancéreuse augmentant significativement le risque de cancer du sein invasif ultérieur, bien qu'il ne constitue pas une tumeur maligne en soi [19]. En revanche, le carcinome lobulaire infiltrant (ILC) est une forme invasive prenant naissance dans les lobules mammaires, et se distingue par une croissance plus diffuse, rendant son diagnostic histologique parfois plus difficile [18].

Certaines formes plus rares, mais souvent associées à un pronostic défavorable, sont également décrites. Parmi elles, le cancer inflammatoire du sein, caractérisé par une évolution rapide et une atteinte fréquente de la peau et des tissus lymphatiques [19]. La maladie de Paget du sein représente une autre forme particulière, marquée par une extension tumorale au niveau du mamelon et de l'aréole [20]. Enfin, les tumeurs phyllodes, issues du tissu conjonctif mammaire, sont le plus souvent bénignes, mais certaines variantes présentent un potentiel malin, nécessitant une prise en charge chirurgicale spécifique [18].

### I.4.2 Classification Moléculaire

Au-delà de la classification histologique, la typologie moléculaire du cancer du sein apporte des informations essentielles sur le comportement tumoral et joue un rôle central dans l'orientation thérapeutique. Cette classification repose sur l'expression des récepteurs hormonaux et de la protéine HER2, permettant de distinguer quatre sous-types principaux [21].

Le sous-type Luminal A se caractérise par une expression positive des récepteurs hormonaux (RH+) et une absence de surexpression de HER2 (HER2-). Ce profil est associé à un pronostic favorable, une croissance lente et une bonne réponse aux traitements hormonaux, ce qui en fait la forme la moins agressive [22].

Le sous-type Luminal B, également RH+, se distingue par une expression variable de HER2 (HER2±) et un indice de prolifération plus élevé. Il est généralement plus agressif que le Luminal A, nécessitant souvent une approche thérapeutique combinant hormonothérapie, chimiothérapie et parfois une thérapie ciblée [23].

Le sous-type HER2+ se définit par une surexpression de la protéine HER2. Bien que ce profil soit associé à une agressivité tumorale accrue, l'introduction de thérapies ciblées, telles que le trastuzumab, a considérablement amélioré le pronostic des patientes atteintes de ce type de cancer [21].

Enfin, le cancer du sein triple négatif (RH-/HER2-) constitue une forme particulièrement agressive, dépourvue de récepteurs hormonaux et de surexpression HER2. L'absence de cibles thérapeutiques rend son traitement complexe et repose essentiellement sur la chimiothérapie, bien que des stratégies émergentes basées sur l'immunothérapie soient actuellement explorées [22].

I.4.3 Stades cliniques (classification TNM)

Tableau 1 : les différentes classifications stades pour le cancer du sein

Stade	Description	Survie à 5 ans
<b>0</b>	Carcinome in situ (DCIS/LCIS)	>99%
<b>I</b>	Tumeur $\leq 2$ cm, pas d'atteinte ganglionnaire	95-100%
<b>IIA</b>	Tumeur $\leq 2$ cm avec ganglions atteints OU 2-5 cm sans ganglions	85-90%
<b>IIB</b>	Tumeur 2-5 cm avec ganglions OU $>5$ cm sans ganglions	80-85%
<b>IIIA</b>	Atteinte de 4-9 ganglions axillaires OU extension mammaire interne	65-70%
<b>IIIB</b>	Extension à la paroi thoracique ou à la peau	40-60%
<b>IIIC</b>	Atteinte $\geq 10$ ganglions ou sus-claviculaires	30-50%
<b>IV</b>	Métastases à distance (os, foie, poumon, cerveau)	~30%

### I.5 l'importance de la détection et du diagnostic précoces :

Le diagnostic précoce du cancer du sein constitue un levier majeur pour améliorer le pronostic vital et la qualité de vie des patientes. En effet, les données épidémiologiques mettent en évidence une corrélation étroite entre le stade de détection et la survie : le taux de survie à cinq ans dépasse 95 % lorsque la tumeur est identifiée aux stades 0 ou I, contre environ 30 % au stade IV, lorsque la maladie est métastatique [24]. Ce constat souligne l'importance d'une prise en charge anticipée, permettant des traitements conservateurs tels que la chirurgie partielle, à la place de gestes plus invasifs comme la mastectomie [25].

La taille tumorale illustre également cet impact : une tumeur localisée d'un centimètre présente un pronostic bien meilleur qu'une lésion de trois centimètres associés à une atteinte ganglionnaire. De plus, la détection précoce ouvre la voie à des traitements moins lourds : dans certains cancers hormonodépendants précoces, l'hormonothérapie seule peut suffire, évitant le recours systématique à la chimiothérapie [26].

Sur le plan économique, un cancer diagnostiqué à un stade avancé engendre des coûts trois à cinq fois supérieurs à ceux d'une prise en charge précoce, en raison de l'intensité thérapeutique requise et de la durée prolongée des hospitalisations [27].

Plusieurs stratégies ont démontré leur efficacité pour améliorer le dépistage. La mammographie, notamment lorsqu'elle est proposée dans le cadre de programmes de dépistage organisé, permet de réduire la mortalité de 20 à 30 % chez les femmes âgées de 50 à 70 ans [28]. L'auto-palpation, bien qu'elle ne remplace pas l'imagerie, constitue une méthode simple pour identifier des anomalies et motiver une consultation médicale rapide [29]. Enfin, l'échographie et l'IRM sont particulièrement recommandées pour les femmes à haut risque, notamment celles porteuses de mutations BRCA.

Malgré ces avancées, la participation aux campagnes de dépistage demeure insuffisante. En France, par exemple, à peine 50 % des femmes éligibles participent régulièrement au dépistage organisé [28]. Cette situation renforce la nécessité de renforcer la sensibilisation et l'information sur les signes d'alerte, tels que la présence d'une masse palpable, un écoulement mamelonnaire ou l'aspect de peau d'orange, afin d'inciter les femmes à consulter sans délai [29].

## **I.6 L'Imagerie Médicale dans le Diagnostic du Cancer du Sein :**

### **I.6.1 Examen mammographique :**

La mammographie est une technique d'imagerie qui utilise des rayons x en très faible quantité (radiographie) et permet d'obtenir des images de la structure interne du sein .[30]

#### **A .Principes :**

La mammographie est une technique d'imagerie médicale reposant sur la radiographie directe du sein, utilisant les propriétés des rayonnements ionisants. Ces rayons, générés par l'impact d'un faisceau d'électrons sur une cible métallique, possèdent la capacité de traverser les tissus humains. Leur atténuation dépend de plusieurs paramètres : l'épaisseur et la densité des structures traversées, ainsi que la longueur d'onde du rayonnement émis. Ce processus donne naissance à une image latente, matérialisée par le noircissement de la pellicule radiographique.

Cependant, une partie du rayonnement est diffusée de manière secondaire, créant un bruit parasite qui diminue le contraste de l'image finale. Pour limiter cette diffusion non constructive, plusieurs dispositifs sont utilisés : une compression adéquate du sein, des cônes de localisation, ainsi que des grilles mobiles anti-diffusantes [31].

L'amélioration de la résolution de l'image passe également par la réduction de la taille du foyer (de 0,6 à 0,3 mm), ce qui diminue le flou géométrique. L'usage d'un film monocouche associé à un écran renforçateur permet d'accroître le contraste tout en réduisant la dose de rayonnement délivrée. De plus, l'emploi de grilles anti-diffusantes améliore la netteté de l'image.

Les avancées technologiques récentes, notamment avec la mammographie numérique directe, offrent de nouvelles perspectives, grâce aux possibilités de traitement d'image numérique qu'elle permet.

La mammographie demeure aujourd'hui l'examen de référence pour le dépistage et le diagnostic des pathologies mammaires. Sa bonne sensibilité, sa précision diagnostique et sa reproductibilité en font l'outil de choix dans la détection précoce du cancer du sein [31].

### **B.Limites de la mammographie :**

Après les essais américains de dépistage de la masse par la mammographie, une controverse passionnée s'est engagée sur le risque des cancers radio-induits par la mammographie. Ce débat a suscité une évaluation rigoureuse des risques réellement. Dans les années 50, l'exposition des films sans écrans nécessitait des doses élevées de 20-100mGray. En 1972, les couples fils-écran aux terres rares permettent de diviser la dose par un facteur 10. La dose à la peau est de 1 à 3 mGray pour une incidence avec un couple film-écran et sans grille [32]. Les études épidémiologiques effectuées chez des femmes ayant subi une irradiation montrent que pour une forte dose (supérieure à 1 Gy), il existe une relation linéaire entre la dose absorbée à la glande et le nombre de cancers en excès. Cependant on ne sait pas réellement ce qui se passe pour les faibles doses comme celles absorbées en mammographie. En pratique, les enquêtes épidémiologiques n'ont pas montré d'élévation significative du nombre de cancers pour des doses inférieures à 1 Gray [33,34].

Pour une mammographie, les recommandations internationales fixent les limites maximales entre 2mGy et 2,5 mGy par incidence.

En fait, la dose délivrée par la mammographie moderne n'est pas négligeable. L'équivalent de sa mortalité actuelle pourrait être associé au risque de faire 113 kilomètres (km) de voyage en avion, 16 km de trajet en voiture, 15 secondes d'alpinisme, de fumer le 1/8 d'une cigarette, ou d'être un homme de 60 ans pendant 3 minutes [35].



**Figure 2 : Image de machine de mammographie[36]**

## **I.6.2 Examen échographique :**

### **A. Princip :**

L'échographie repose sur l'utilisation des ultrasons, qui sont des ondes acoustiques et élastiques. Dans un milieu homogène, ces ondes se propagent en ligne droite et s'atténuent conformément à la loi de l'inverse du carré de la distance. En revanche, dans un milieu hétérogène, les ultrasons rencontrent des interfaces où ils sont partiellement réfléchis, générant ainsi des échos. Lorsqu'une discontinuité entre deux milieux aux propriétés acoustiques différentes est rencontrée, une partie de l'énergie est transmise dans la direction du faisceau, tandis que l'autre est réfléchi à l'interface. Si cette interface est perpendiculaire au faisceau, l'écho est capté par la sonde et traité par l'appareil. En revanche, si l'interface est oblique, l'écho réfléchi ne revient pas à la sonde, ce qui entraîne une perte de signal et une atténuation supplémentaire. L'intensité de l'écho dépend de la différence d'impédance acoustique (liée à l'élasticité et à la densité) entre les deux milieux traversés. Ainsi, les ultrasons se propagent aisément dans les tissus hydriques, mais rencontrent une réflexion totale lorsqu'ils frappent une structure osseuse ou gazeuse, en raison du contraste acoustique élevé avec l'eau, ce qui empêche leur propagation en profondeur. Les ondes ultrasonores sont produites à l'aide de cristaux piézoélectriques, capables de convertir l'énergie électrique en vibration mécanique et

inversement. Les sondes à haute fréquence permettent une imagerie fine en surface, tandis que les sondes à basse fréquence sont mieux adaptées à l'exploration des structures profondes [37].

### B. Les limites de l'échographie :

Le taux de positivité atteint 95% de diagnostics exacts et 6% des cas douteux. Le taux de fausse positivité est de 14%. Le taux de tissu négatifs est de 4,20% [38], il y aurait 85% de diagnostic exacts pour les T1 et 66% pour les T0.

### C. Indications de l'Échographie Mammaire :

L'échographie mammaire constitue un outil diagnostique fondamental, particulièrement recommandé dans diverses situations cliniques spécifiques. Elle est notamment indiquée pour la recherche d'une tumeur primitive en présence d'une adénopathie axillaire métastatique. En raison de la densité importante du tissu mammaire chez les jeunes patientes, elle est préférée chez les femmes de moins de 25 ans, ainsi que chez les femmes enceintes de moins de trois mois et les nourrices, en raison de l'absence d'irradiation. L'échographie est également utile dans l'évaluation de nodule(s) suspects, de fibroadénomes ou en cas de suspicion de multifocalité tumorale. Elle constitue une alternative fiable lorsque la mammographie est difficile ou impossible à réaliser, notamment après une intervention chirurgicale récente sur le sein ou chez les patientes porteuses de prothèses mammaires. Enfin, en cas de mastectomie, l'échographie mammaire reste le principal examen d'imagerie pour explorer la paroi thoracique [39].



**figure 3 : présenter la machine de l'échographe. [40]**

### I.6.3 L'IRM mammaire :

L'imagerie par résonance magnétique (IRM) mammaire représente une technique en constante évolution, dont l'utilité est désormais largement reconnue dans le domaine de l'imagerie du sein. Son principal atout réside dans sa capacité à fournir une analyse fonctionnelle détaillée de la vascularisation tumorale, ce qui la rend particulièrement intéressante dans certaines situations cliniques. Bien que la mammographie et l'échographie mammaire restent les examens de première intention pour le dépistage et le diagnostic du cancer du sein, en raison de leur sensibilité, de leur reproductibilité et de leur accessibilité, les indications de l'IRM mammaire ne cessent de s'élargir [41].



**figure 4 : présenter la machine de l'IRM [42]**

### I.6.4 La scintigraphie :

Il s'agit d'une méthode d'imagerie fonctionnelle basée sur l'émission de rayons gamma par des traceurs radioactifs. Relativement récente, cette technique est principalement utilisée en médecine nucléaire. Elle repose sur l'injection intraveineuse d'une substance radioactive, suivie de la détection de la radioactivité émise dans l'organisme à l'aide de caméras spécifiques. Elle permet à la fois d'effectuer un diagnostic précis et d'explorer certaines fonctions physiologiques. En imagerie mammaire, cette méthode est particulièrement utile pour la détection des chaînes ganglionnaires, notamment des ganglions axillaires ou mammaires internes susceptibles de contenir des métastases. Elle offre également un avantage

thérapeutique : dans certains cas, elle permet de cibler spécifiquement les ganglions atteints pour un traitement localisé par irradiation, épargnant ainsi les tissus sains environnants, comme le reste du sein ou la paroi thoracique [43].



**figure 5 : présenter la machine de la scintigraphie [44]**

I.6.5 RESULTATS/ ICONOGRAPHIES :

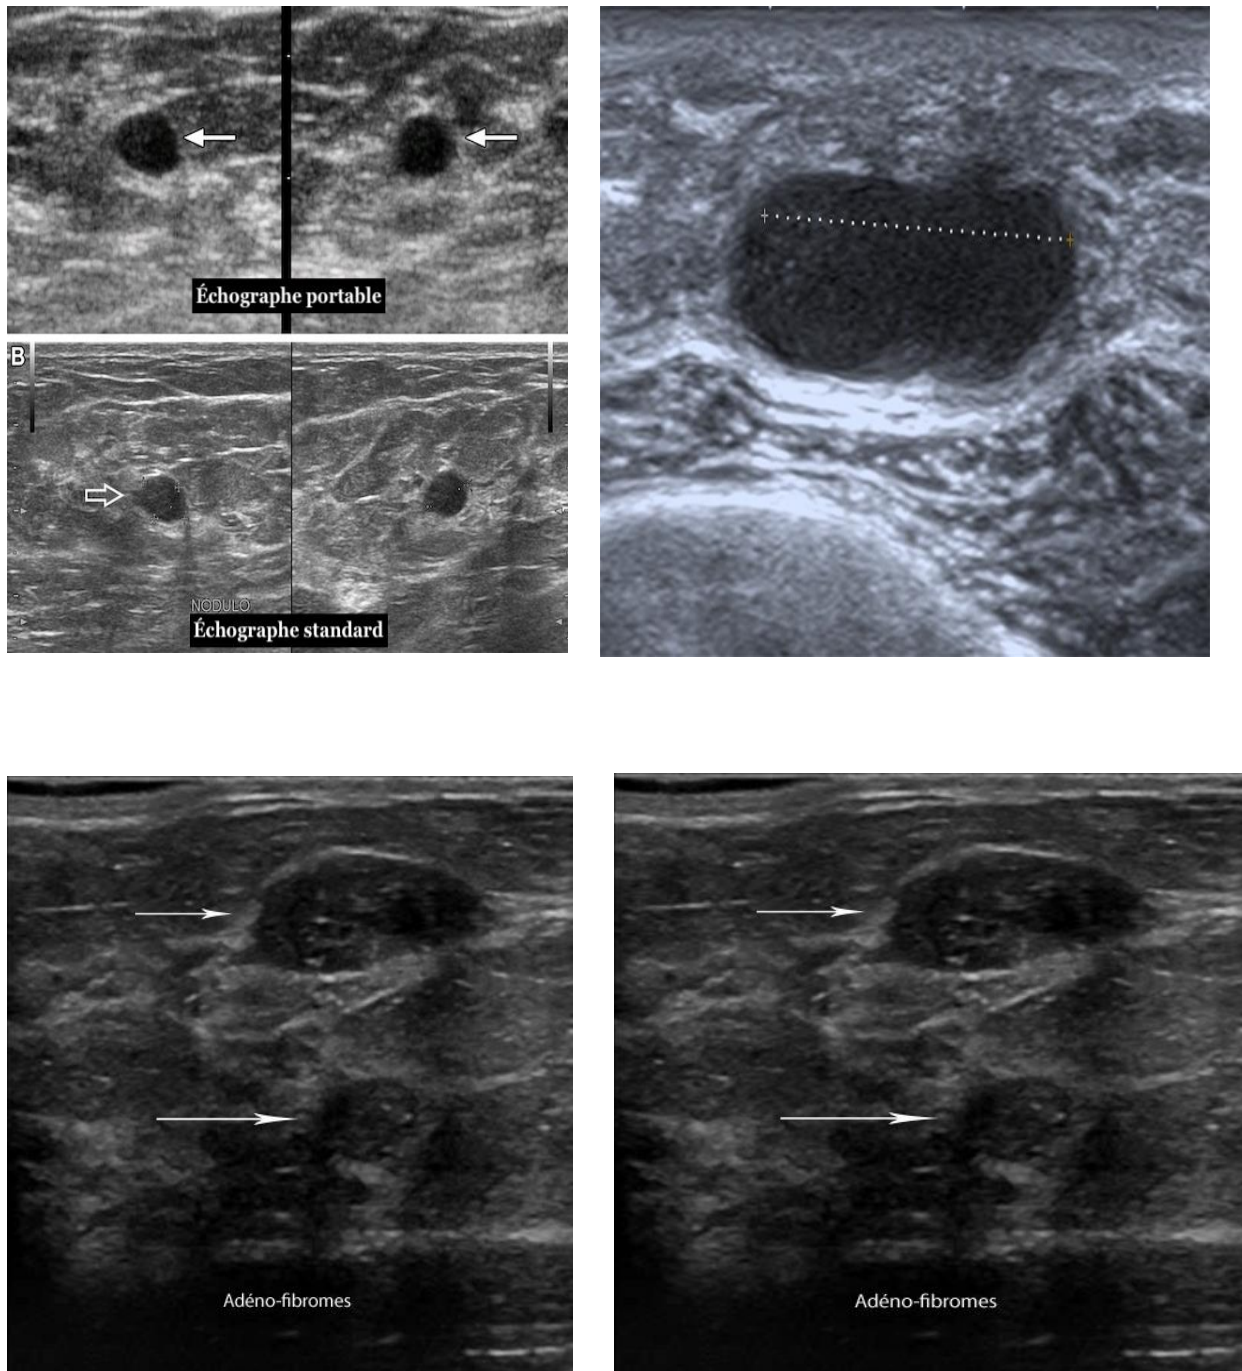


figure 6 : présenter les images pour la diagnostic de cancer de sein à partir de l'échographie

### I.7 La Segmentation d'Images: Fondements et Importance :

#### I.7.1 Définition de la segmentation en imagerie médicale :

La segmentation en imagerie médicale est un processus essentiel qui vise à diviser une image en régions distinctes et significatives, dans le but d'isoler et de délimiter avec précision des structures anatomiques spécifiques ou des anomalies pathologiques, telles qu'un organe, une tumeur, une lésion ou toute zone d'intérêt clinique [45]. Dans le contexte du cancer du sein, la segmentation joue un rôle fondamental en permettant de détecter et contourer précisément la tumeur à partir d'images obtenues par mammographie, échographie ou IRM. Cette étape facilite non seulement l'analyse qualitative et quantitative des lésions, mais aussi leur suivi évolutif et leur prise en charge thérapeutique.

#### I.7.2 Objectif de la segmentation :

- Extraire automatiquement ou semi-automatiquement les zones d'intérêt.
- Faciliter l'interprétation médicale.
- Aider à la quantification (taille, forme, volume).
- Servir de base à des tâches ultérieures : classification, détection, planification thérapeutique, etc.[46]

#### I.7.3 L'importance d'une segmentation précise dans l'analyse d'images médicales : Application au cancer du sein :

La segmentation des images médicales joue un rôle fondamental en oncologie mammaire, en apportant des bénéfices majeurs tant sur le plan diagnostique que thérapeutique. Tout d'abord, elle permet une détection et une délimitation précises des tumeurs [47]. Une segmentation fine facilite la distinction entre les tissus sains et les tissus tumoraux, ce qui est essentiel pour localiser avec précision la tumeur à travers différentes modalités d'imagerie (mammographie, échographie, IRM), pour différencier les lésions bénignes des tumeurs malignes (par exemple, un kyste versus un carcinome), et pour réduire les risques de faux positifs ou de faux négatifs, améliorant ainsi la fiabilité du diagnostic. Ensuite, la segmentation permet une évaluation quantitative du volume tumoral [48]. En mesurant avec exactitude le diamètre, la surface et le volume de la tumeur, elle contribue à la classification TNM (Tumeur, Node, Metastasis) et permet un suivi objectif de la réponse au traitement, notamment dans le cadre des chimiothérapies néoadjuvantes. Par ailleurs, la segmentation est également

indispensable à la planification chirurgicale et radiothérapeutique [49]. En chirurgie mammaire conservatrice (tumorectomie), elle assure une exérèse complète de la lésion tout en préservant les tissus sains, tandis qu'en radiothérapie, elle permet de cibler avec précision la zone à traiter, limitant ainsi l'exposition des structures adjacentes. Enfin, la segmentation joue un rôle clé dans le suivi longitudinal et l'évaluation de la réponse thérapeutique, en fournissant des contours reproductibles pour comparer les images avant et après traitement, suivre la régression tumorale et détecter précocement les récives.

### I.7.4 Défis de la Segmentation des Images Mammaires en Oncologie :

La segmentation des images mammaires, bien qu'indispensable pour le diagnostic et le traitement du cancer du sein, demeure une tâche complexe en raison de nombreux défis techniques et biologiques qui nécessitent des méthodes à la fois précises et robustes. Tout d'abord, la grande variabilité d'apparence des tumeurs [50] rend leur détection difficile : leur morphologie peut être très hétérogène (formes spiculées, lobulées ou diffuses), leur texture irrégulière, et leur contraste variable selon la densité tissulaire, ce qui complique la différenciation avec les structures normales telles que les adipocytes ou les glandes mammaires. Ensuite, le faible contraste dans certaines modalités d'imagerie [51] aggrave encore cette difficulté. En mammographie, par exemple, la densité mammaire importante chez les jeunes femmes masque souvent les lésions suspectes ; en IRM dynamique, les variations de rehaussement du signal rendent la délimitation incertaine ; et en échographie, le bruit de speckle ainsi que les artéfacts acoustiques perturbent la lisibilité des contours tumoraux. Par ailleurs, la présence de bruits et d'artéfacts [52] reste un obstacle majeur : bruits de capteurs en mammographie ou en échographie, flous liés aux mouvements du patient en IRM, ou encore artéfacts de compression pouvant simuler de fausses masses. Dans ce contexte, les méthodes manuelles, bien que précises dans certaines situations, sont longues, subjectives et difficiles à reproduire. Il devient alors crucial de recourir à des approches automatiques et intelligentes [53], notamment grâce aux réseaux de neurones convolutifs (CNN), et en particulier l'architecture U-Net, qui a montré son efficacité pour la segmentation biomédicale. L'intégration de techniques de prétraitement (filtrage, normalisation, réduction du bruit), ainsi que l'exploitation de la fusion multimodale (combinant les informations issues de la mammographie, de l'IRM et de l'échographie) apparaissent comme des solutions prometteuses pour surmonter ces limitations et améliorer la fiabilité de la segmentation automatique.

### I.8 Structure Proposée pour les Chapitres

1. Rôle de l'Informatique et de l'Ordinateur dans l'Amélioration de la Qualité du Diagnostic des Images Médicales et l'État de l'Art en Segmentation
2. Techniques Classiques et Méthodes d'Apprentissage Profond pour la Segmentation des Images Médicales
3. Comparaison Détaillée entre les Méthodes Classiques et les Méthodes d'Apprentissage Profond
4. Comparaison des Résultats de l'Apprentissage Profond avec l'État de l'Art
5. Tour d'Horizon des Perspectives Futures pour le analyse des Images Médicales

Cette approche permettra de déterminer quelle technologie (traditionnelle ou IA) est la plus adaptée pour améliorer le diagnostic et le traitement du cancer du sein.

### I.9 Conclusion :

À l'issue de ce chapitre, nous avons mis en évidence l'ampleur du cancer du sein, tant au niveau mondial qu'en Algérie, en soulignant sa prévalence croissante, ses facteurs de risque, ainsi que les défis liés à son dépistage. L'importance d'un diagnostic précoce a été démontrée, notamment grâce aux outils d'imagerie médicale tels que l'échographie, l'IRM et la mammographie, qui jouent un rôle essentiel dans la détection des lésions mammaires.

Nous avons également introduit le concept fondamental de la segmentation d'images médicales, une étape cruciale dans l'analyse et l'interprétation des données échographiques. Cette technique permet d'isoler la région tumorale afin d'en extraire des caractéristiques morphologiques utiles au diagnostic et à la planification thérapeutique.

Ayant ainsi établi le contexte médical et technique de notre travail, le chapitre suivant sera consacré à la présentation des méthodes classiques de segmentation, en décrivant leurs principes, leurs limites, ainsi que les résultats qu'elles permettent d'obtenir sur des images échographiques. Cela nous permettra de mieux comprendre les motivations qui justifient le recours à des techniques plus avancées, fondées sur l'apprentissage profond.

---

---

# **Chapitre II : le rôle de l'informatique dans l'analyse des images médicales et L'état de l'art**

---

---

# **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

## **II.1 Introduction :**

L'imagerie médicale constitue aujourd'hui un pilier fondamental de la médecine moderne. Des radiographies conventionnelles aux techniques avancées telles que l'imagerie par résonance magnétique (IRM) ou la tomodensitométrie (TDM), ces modalités offrent aux cliniciens une fenêtre précieuse sur l'anatomie interne du corps humain. Elles sont essentielles au diagnostic précoce des maladies, à la planification de traitements complexes, ainsi qu'au suivi précis de l'évolution thérapeutique. La capacité à localiser des anomalies, à mesurer des structures ou à observer la progression d'une pathologie a profondément transformé la prise en charge médicale, permettant des interventions plus ciblées et personnalisées.

Cependant, l'explosion du volume et de la complexité des données d'imagerie rend leur analyse manuelle de plus en plus difficile. Examiner des milliers d'images chaque jour peut s'avérer fastidieux, entraîner une fatigue visuelle importante, induire une variabilité inter-observateurs, et conduire à l'omission de détails subtils mais cliniquement significatifs. Dans ce contexte, l'apport de l'informatique médicale devient non seulement pertinent, mais indispensable. Les outils informatiques permettent d'automatiser les tâches répétitives, d'améliorer la précision des mesures et, surtout, de détecter des motifs imperceptibles à l'œil humain, allégeant ainsi la charge de travail des professionnels de santé tout en renforçant la qualité des diagnostics.

Ce volet présente les apports majeurs de l'informatique dans le domaine de l'analyse d'images médicales. Il met en évidence les différentes approches de traitement et d'interprétation des images, allant des techniques classiques aux méthodes avancées basées sur l'intelligence artificielle et l'apprentissage profond. L'objectif principal est de démontrer comment ces innovations technologiques contribuent à transformer la pratique clinique, en optimisant la précision, la rapidité et la fiabilité du diagnostic médical.

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

### II.2 Fondamentaux du Traitement d'Images Numériques en Médecine :

Le traitement numérique des images médicales constitue le socle de toute analyse assistée par ordinateur. Il regroupe un ensemble de techniques visant à manipuler les images afin d'en améliorer la qualité, d'en extraire des informations pertinentes, et de les préparer à des analyses plus avancées, notamment celles reposant sur l'intelligence artificielle. Ces étapes préliminaires sont essentielles pour assurer la fiabilité et la précision des résultats finaux.

#### II.2.1 Prétraitement : Amélioration de la qualité des images

##### Définition:

Le prétraitement constitue une étape fondamentale dans l'analyse des images médicales, en particulier dans le domaine de l'imagerie échographique. Son objectif principal est d'améliorer la qualité des images brutes afin d'optimiser les performances des traitements ultérieurs, tels que la segmentation, la détection automatique ou encore la classification des structures anatomiques. Bien que l'échographie soit largement appréciée pour son accessibilité, son faible coût et son innocuité, les images qu'elle produit sont souvent altérées. Elles sont notamment affectées par le bruit de speckle — un bruit de nature multiplicative — qui dégrade la lisibilité des structures internes. Par ailleurs, ces images présentent fréquemment un faible contraste, ce qui complique la distinction entre les tissus sains et pathologiques [54].

##### II.2.1.1 Réduction du bruit :

###### A.Principe :

Les images échographiques sont particulièrement affectées par le bruit de speckle, un artefact qui dégrade considérablement leur qualité visuelle. La réduction de ce bruit a pour objectif de le supprimer tout en préservant les bords et les structures anatomiques essentielles. Parmi les techniques les plus couramment utilisées, on trouve :

- **Le filtre médian** : il remplace la valeur de chaque pixel par la médiane de ses voisins, permettant ainsi de supprimer efficacement les bruits impulsifs tout en conservant les contours nets.
- **La diffusion anisotropique** : elle applique un lissage sélectif, atténuant le bruit dans les zones homogènes tout en préservant les contours des structures, ce qui améliore la lisibilité sans perte d'information significative. [55.56]

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

### B. Principe mathématique :

#### ◆ Filtre médian

Soit  $I(i,j)$  l'intensité du pixel au point  $(i,j)$ . Alors :

$$I_{\text{filtre}}'(i,j) = \text{médiane}\{I(k,l) \in N(i,j)\}$$

où  $N(i,j)$  est un voisinage autour du pixel.

#### ◆ Diffusion anisotropique (Perona-Malik)

La diffusion est régie par l'équation :

$$\frac{\partial I}{\partial t} = \nabla \cdot (c(x,y,t) \cdot \nabla I)$$

Où  $c(x,y,t)$  est une fonction de conductivité dépendante du gradient de l'image.

### II.2.1.2 Amélioration du contraste :

#### A.Principe :

L'amélioration du contraste est une étape clé dans le prétraitement des images échographiques, car elle permet de mieux distinguer les structures internes en renforçant la différence de luminosité entre les régions tissulaires. Cette opération est particulièrement importante pour faciliter l'interprétation visuelle par les cliniciens, mais aussi pour améliorer la performance des algorithmes automatisés de segmentation ou de détection.

Deux méthodes sont couramment utilisées :

- **L'égalisation d'histogramme** globale,
- **La méthode CLAHE** (Contrast Limited Adaptive Histogram Equalization), qui agit localement tout en limitant l'amplification du bruit. [57,58]

# Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

## 🚩 B. Principe mathématique:

### ◆ Égalisation d'histogramme

L'intensité transformée est :

$$I_{\text{égal}} = CDF(I) \times (L - 1)$$

avec L le nombre de niveaux de gris, et CDF la fonction de répartition cumulative.

### ◆ CLAHE

La CLAHE divise l'image en sous-blocs, applique une égalisation locale, et limite le contraste par un clip limit pour éviter l'amplification du bruit.

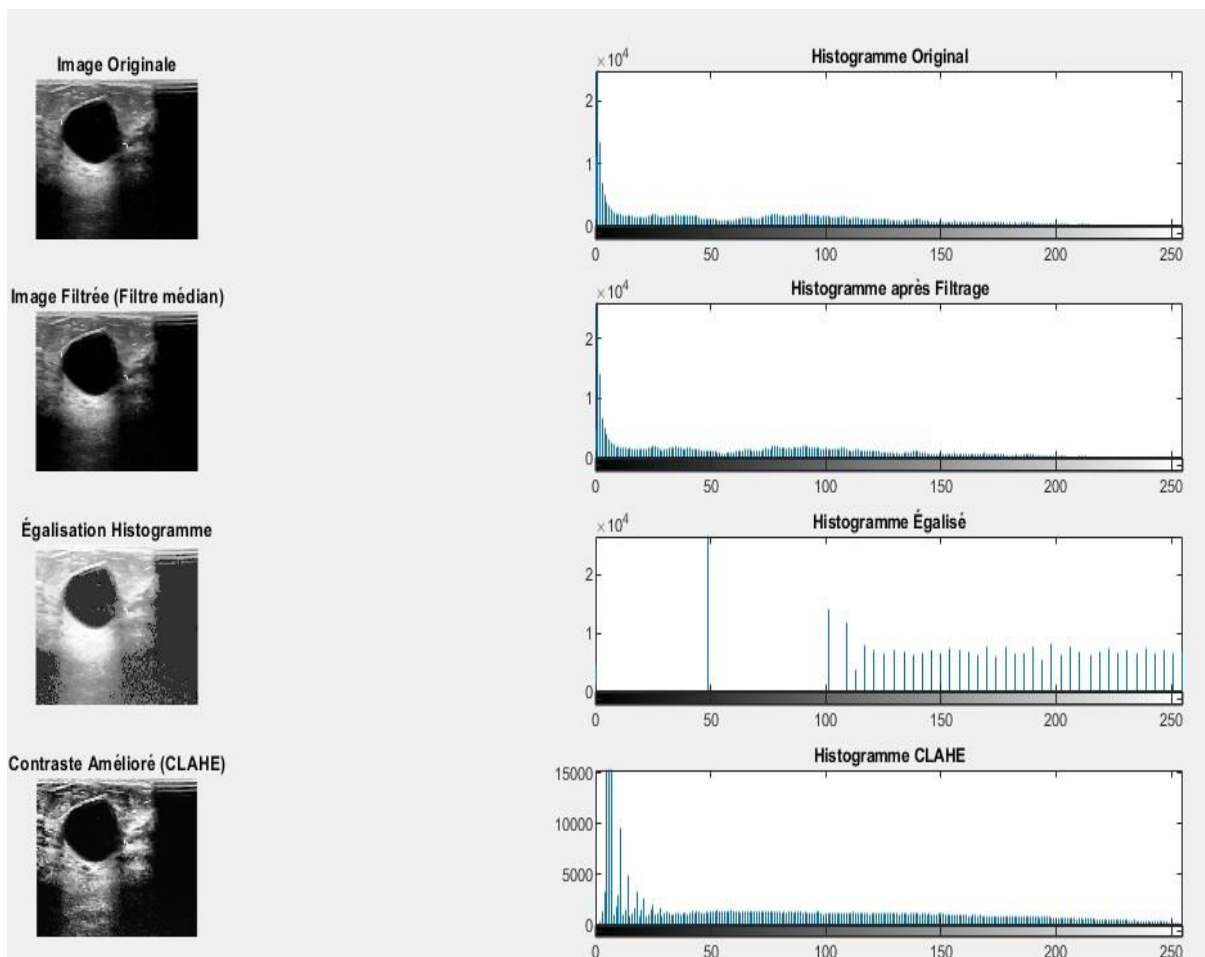


figure 7 : présentation pour l'image originale après le Prétraitement

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

### II.2.2 Segmentation :

Définition : La segmentation consiste à isoler, de manière automatique ou manuelle, les structures d'intérêt présentes dans une image, telles que les organes, les lésions ou les tumeurs. Elle permet de différencier les régions anatomiques ou pathologiques, ce qui constitue une étape indispensable pour les analyses quantitatives, la planification thérapeutique et les diagnostics assistés par ordinateur [59, 60].

#### 1. Méthodes basées sur le seuil (seuillage) :

Les méthodes de seuillage consistent à séparer les objets d'intérêt du fond de l'image en définissant une valeur seuil d'intensité. Tous les pixels dont l'intensité est supérieure (ou inférieure) à ce seuil sont alors considérés comme appartenant à la région d'intérêt (ROI), tandis que les autres sont classés comme appartenant à l'arrière-plan. Ce processus permet généralement de transformer une image en niveaux de gris en une image binaire, facilitant ainsi l'analyse et la segmentation automatique des structures. Le choix du seuil peut être effectué de manière manuelle, automatique — comme avec la méthode d'Otsu — ou encore adaptative, en tenant compte des variations locales d'intensité présentes dans l'image [61, 62].

#### Principe mathématique :

$$B(x,y) = 255 \text{ si } I(x,y) \geq T$$

$$B(x,y) = 0 \text{ si } I(x,y) < T$$

où  $I(x,y)$  est l'intensité du pixel et  $T$  le seuil.

#### 2. Méthodes basées sur les régions :

Définition : Les méthodes de segmentation basées sur les régions consistent à regrouper les pixels adjacents présentant des caractéristiques similaires — telles que l'intensité, la texture ou la couleur — afin de former des zones homogènes au sein de l'image. L'objectif de ces techniques est d'extraire des régions localement cohérentes sur le plan statistique, facilitant ainsi l'identification de structures anatomiques ou pathologiques. Parmi ces approches, la croissance de région est l'une des plus courantes. Elle nécessite un point de

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

Un point de départ initial (ou *seed*) à partir duquel l'algorithme étend progressivement la région, en intégrant les pixels voisins satisfaisant un critère de similarité prédéfini [63, 64].

### 🚩 Principe mathématique :

À partir d'un pixel initial, on ajoute récursivement les pixels voisins qui satisfont un critère d'homogénéité :

$$| I(x, y) - \mu | < \epsilon$$

Où  $\mu$  est l'intensité moyenne de la région et  $\epsilon$  epsilon un seuil de tolérance.

### 3. Méthodes basées sur les contours (ou détection de bords) :

Définition : Les méthodes de segmentation basées sur les contours ont pour objectif de détecter les frontières entre les différentes régions d'une image, en se fondant sur les variations abruptes d'intensité, appelées gradients. Ces transitions correspondent généralement aux limites des structures anatomiques ou pathologiques. Pour identifier ces contours, on utilise des opérateurs de détection de bords tels que Sobel, Prewitt ou Canny, qui mettent en évidence les discontinuités d'intensité dans l'image. Des approches plus avancées, comme les courbes actives (ou *snakes*), modélisent les contours comme des courbes dynamiques influencées par des forces internes, qui assurent le lissage et la continuité de la forme, et par des forces externes, issues de l'image, qui attirent la courbe vers les bords significatifs. [65,66]

### 🚩 Principe mathématique :

$$| \nabla I(x, y) | = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$$

**Tableau 2 : Comparaison des méthodes classiques de segmentation d'images médicales**

Méthode	Principe	Avantages	Inconvénients
Seuillage	Comparaison à un seuil d'intensité	Simple, rapide	Sensible au bruit, dépend fortement du seuil
Basée sur les régions	Regroupement des pixels similaires	Bonne détection des régions homogènes	Dépend du point de départ et du critère choisi
Basée sur les contours	Détection des bords par le gradient	Bonne localisation des frontières	Sensible au bruit ou au flou

### II.2.3 Caractérisation et Quantification : Mesure et description des éléments segmentés :

Après la segmentation des structures d'intérêt, l'étape suivante est l'extraction de caractéristiques quantitatives (*radiomique*). Celles-ci comprennent des paramètres morphologiques (surface, volume, forme), d'intensité (moyenne, écart-type) et texturaux (contraste, entropie, homogénéité, souvent dérivés de la GLCM). Ces descripteurs numériques permettent de différencier l'état physiologique ou pathologique d'un tissu, par exemple distinguer une tumeur bénigne d'une maligne [67].

### II.2.4 Enregistrement (Registration) : Alignement d'Images pour Comparaison ou Fusion

L'enregistrement d'images, également appelé recalage ou fusion d'images, désigne le processus d'alignement géométrique de deux ou plusieurs images afin que des points anatomiques homologues correspondent entre elles. Cette technique joue un rôle fondamental pour comparer des images acquises à différents moments (suivi temporel), pour fusionner des modalités complémentaires telles que l'IRM et la TDM afin d'obtenir une vision plus complète, ou encore pour aligner les images de patients avec des atlas anatomiques [68].

L'objectif principal est de déterminer une transformation optimale — qu'il s'agisse d'une translation, d'une rotation, d'une mise à l'échelle ou d'une déformation non rigide —

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

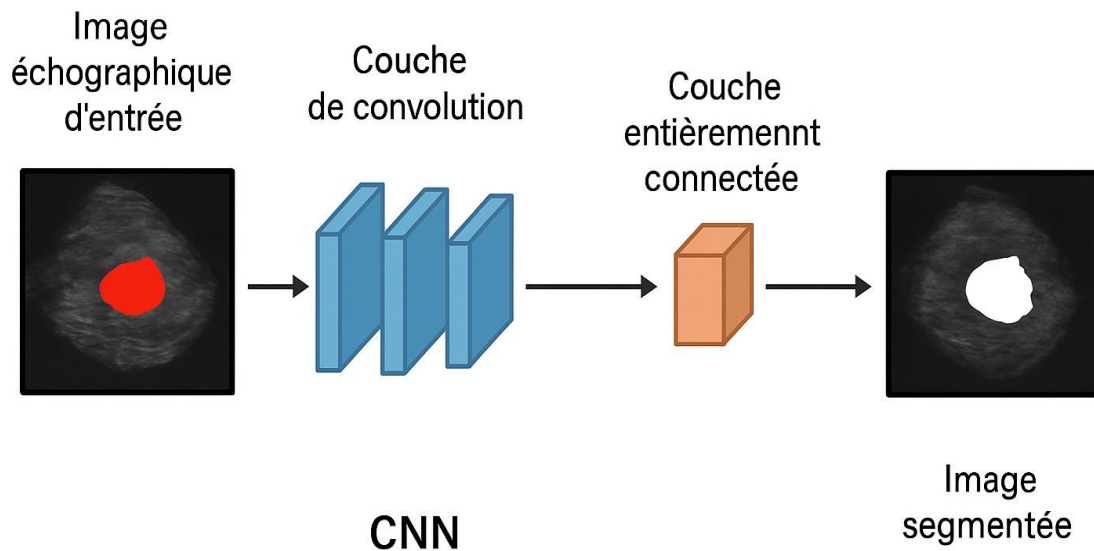
permettant d'aligner les structures d'intérêt. Les approches incluent les transformations rigides et affines, adaptées aux structures globales, ainsi que les déformations élastiques et non rigides, plus pertinentes pour l'adaptation locale des tissus [69].

Les applications cliniques sont nombreuses : planification chirurgicale, guidage d'interventions, suivi de l'évolution des pathologies et construction de modèles tridimensionnels personnalisés.

### **II.3 L'Apport de l'Intelligence Artificielle et de l'Apprentissage Profond :**

#### **II.3.1 Architecture et Composants Clés des CNN**

Les réseaux de neurones convolutifs (CNN) constituent une architecture d'apprentissage profond spécialement conçue pour le traitement d'images. Leur fonctionnement repose sur plusieurs composants clés : les couches de convolution, qui extraient automatiquement des caractéristiques locales à l'aide de filtres sensibles aux bords, aux textures et aux motifs ; les fonctions d'activation (comme ReLU), qui introduisent de la non-linéarité et permettent au modèle de capturer des relations complexes ; les couches de pooling, qui réduisent la dimensionnalité et améliorent la robustesse aux variations locales ; puis les couches entièrement connectées, responsables de la combinaison des caractéristiques extraites pour effectuer la classification finale. Dans la plupart des cas, la dernière étape consiste en une couche Softmax, qui convertit les scores obtenus en probabilités normalisées, facilitant ainsi l'interprétation des résultats. Grâce à cette organisation hiérarchique, les CNN se sont imposés comme une méthode de référence en vision par ordinateur et en imagerie médicale [70,71].



**figure 8 : Schéma d'un CNN appliqué à la segmentation des images échographiques du cancer du sein**

### II.3.2 Avantages des CNN pour la Segmentation d'Images :

La segmentation d'images constitue une étape essentielle du traitement d'images, visant à attribuer une étiquette ou une classe spécifique à chaque pixel d'une image. Elle permet de délimiter avec précision les différentes régions d'intérêt, telles que les structures anatomiques ou les anomalies pathologiques. Les réseaux de neurones convolutifs (CNN) se sont avérés particulièrement efficaces pour cette tâche, grâce à plusieurs propriétés fondamentales de leur architecture et de leur fonctionnement.

#### 1. Hiérarchie des Caractéristiques et Détection de Motifs

Les CNN excellent dans l'apprentissage d'une hiérarchie de caractéristiques à partir de données brutes. Les premières couches détectent des caractéristiques simples comme les bords et les coins, tandis que les couches plus profondes combinent ces éléments pour reconnaître des motifs et des formes complexes. Cette capacité permet aux modèles de comprendre l'image à plusieurs niveaux de granularité, ce qui est crucial pour la segmentation, car il faut à la fois une vue d'ensemble (contexte de l'objet) et une vue détaillée (limites précises).[72]

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

### **2. Efficacité Spatiale**

Grâce à leurs couches de convolution et de pooling, les CNN réduisent la complexité des données tout en préservant les informations spatiales importantes. Le partage des poids (convolution) permet de détecter le même motif n'importe où dans l'image, ce qui réduit considérablement le nombre de paramètres et rend le modèle plus efficace. De plus, la segmentation sémantique utilise souvent des architectures comme les réseaux encodeur-décodeur (tels que U-Net) qui capturent le contexte global (encodeur) et utilisent des connexions résiduelles (skips connections) pour reconstruire une carte de segmentation haute résolution (décodeur), assurant ainsi une localisation précise des objets. [72]

### **3. Invariance aux Translations**

Un avantage fondamental des CNN est leur invariance aux translations. Cela signifie que le réseau peut reconnaître un objet même s'il est déplacé, tourné ou redimensionné dans l'image. Cette capacité est essentielle en segmentation, car elle garantit que le modèle peut identifier les pixels d'un objet indépendamment de sa position. Par exemple, un CNN entraîné pour segmenter des voitures reconnaîtra une voiture qu'elle soit au centre ou sur le côté de l'image. [72]

## **II.3.3 Architectures CNN pour la Segmentation d'Images Médicales :**

### **1.U-Net :**

L'architecture U-Net se fonde sur un concept élégant : celui du réseau entièrement convolutif (FCN). L'un des défis majeurs des FCN classiques réside dans leur forte dépendance à de vastes ensembles de données pour un apprentissage efficace. U-Net a été conçu comme une extension et une modification astucieuse de cette architecture, ce qui lui permet d'opérer avec un nombre très limité d'images d'apprentissage tout en garantissant une segmentation d'une grande précision.

C'est pourquoi U-Net est devenu un choix prépondérant dans de nombreuses études et applications axées sur la segmentation d'images médicales. Comme l'illustre la Figure 9, son architecture est caractérisée par une séquence de couches de sous-échantillonnage (ou réduction de la résolution) et de suréchantillonnage (ou augmentation de la résolution). Un aspect novateur de U-Net est la connexion des couches de suréchantillonnage avec les sorties des couches correspondantes du chemin de sous-échantillonnage (les "skip connections"). Ce

## Chapitre I I : le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

mécanisme assure que la sortie finale du réseau maintient la même résolution spatiale que l'image d'entrée, un atout crucial pour une segmentation détaillée.




figure 9 : Exemple de segmentation sémantique avec U-Net[73]

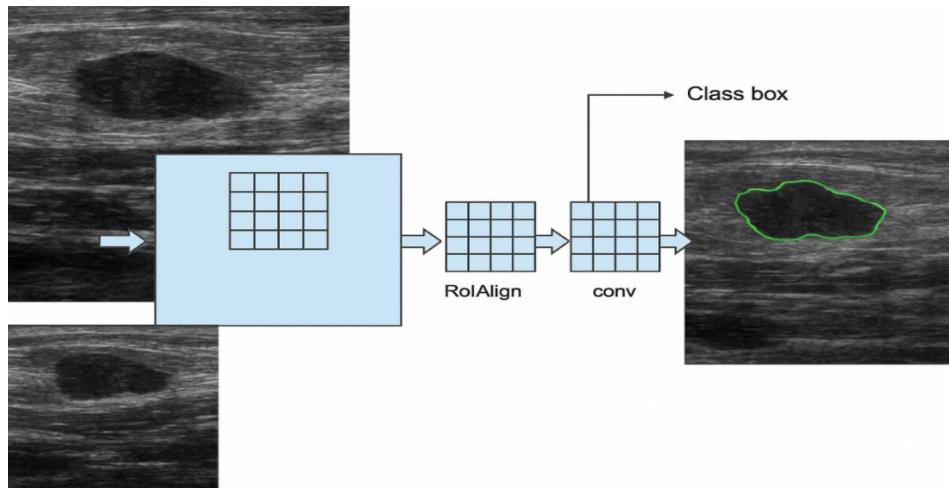
### 2.Mask R-CNN :

Le modèle original Mask R-CNN a été développé en 2017 comme prédécesseur du Faster R-CNN, en l'étendant à la segmentation sémantique, à la localisation d'objets et à la segmentation d'instances d'objets pour les images. Mask R-CNN est un cadre simple, flexible et général pour la segmentation d'instances d'objets. Utilisant ResNet-101-FPN, Mask R-CNN a surpassé tous les modèles de pointe, y compris une variante de MNC, FCIS et les autres modèles participant au défi COCO 2016, un défi de détection et de segmentation d'objets à grande échelle.

Mask R-CNN est un réseau de segmentation d'instances basé sur la proposition de régions, qui génère des régions avant la segmentation. La figure 10 représente Mask R-CNN, une architecture de réseau multi-étapes dotée de son propre pipeline pour la segmentation et la classification des instances. Le R-CNN masqué est similaire au R-CNN plus rapide : les caractéristiques sont d'abord extraites à l'aide d'un réseau fédérateur, puis d'un réseau de proposition de régions, puis de RoIAlign, qui convertit les tailles variables des régions en une

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

matrice de dimension standard, adaptée aux étapes suivantes. Les cartes d'activation après RoIAlign sont fournies en entrée pour la tête du réseau, qui est un petit FCN. Enfin, deux branches, un masque et un prédicteur de classe, sont utilisés pour effectuer la segmentation sémantique et la classification de manière indépendante. [74]



**figure 10: Exemple de segmentation sémantique avec Mask R-CNN**

### 3. SegNet :

SegNet est une architecture novatrice, initialement conçue pour la segmentation sémantique dans le contexte des scènes de conduite autonome, mais qui s'est révélée particulièrement performante pour l'analyse d'images médicales. Proposé en 2015 par Vijay Badrinarayanan, Alex Kendall et Roberto Cipolla de l'Université de Cambridge, SegNet se distingue par une conception unique et efficace.

Son architecture repose sur deux composantes principales :

- L'encodeur (basé sur VGG-16) : Cette partie du réseau est constituée d'une succession de couches de convolution, suivies d'activations ReLU (*Rectified Linear Unit*) et d'opérations de max pooling. Une caractéristique distinctive de SegNet réside dans le fait que chaque opération de max pooling enregistre précisément les indices (c'est-à-dire les positions exactes) des valeurs maximales sélectionnées. Ces indices jouent un rôle crucial lors de l'étape de décodage.
- Le décodeur : Contrairement à d'autres architectures de segmentation, le décodeur de SegNet réalise un "unpooling" à chaque étape. Ce processus de déconvolution s'appuie directement sur les indices mémorisés lors des opérations de max pooling

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

correspondantes, ce qui permet d'éviter les interpolations classiques pour la reconstruction spatiale. Chaque opération d'unpooling est suivie de convolutions et d'activations ReLU. Il est important de noter qu'à la différence de l'U-Net, SegNet n'utilise pas de connexions de saut (*skip connections*) reliant directement les couches de l'encodeur à celles du décodeur.

- La couche de sortie : Enfin, une couche Softmax est appliquée à chaque pixel, permettant au réseau de prédire la probabilité d'appartenance de chaque pixel à une classe sémantique donnée. Cela aboutit à la génération d'une carte de segmentation précise et détaillée de l'image d'entrée.[75]

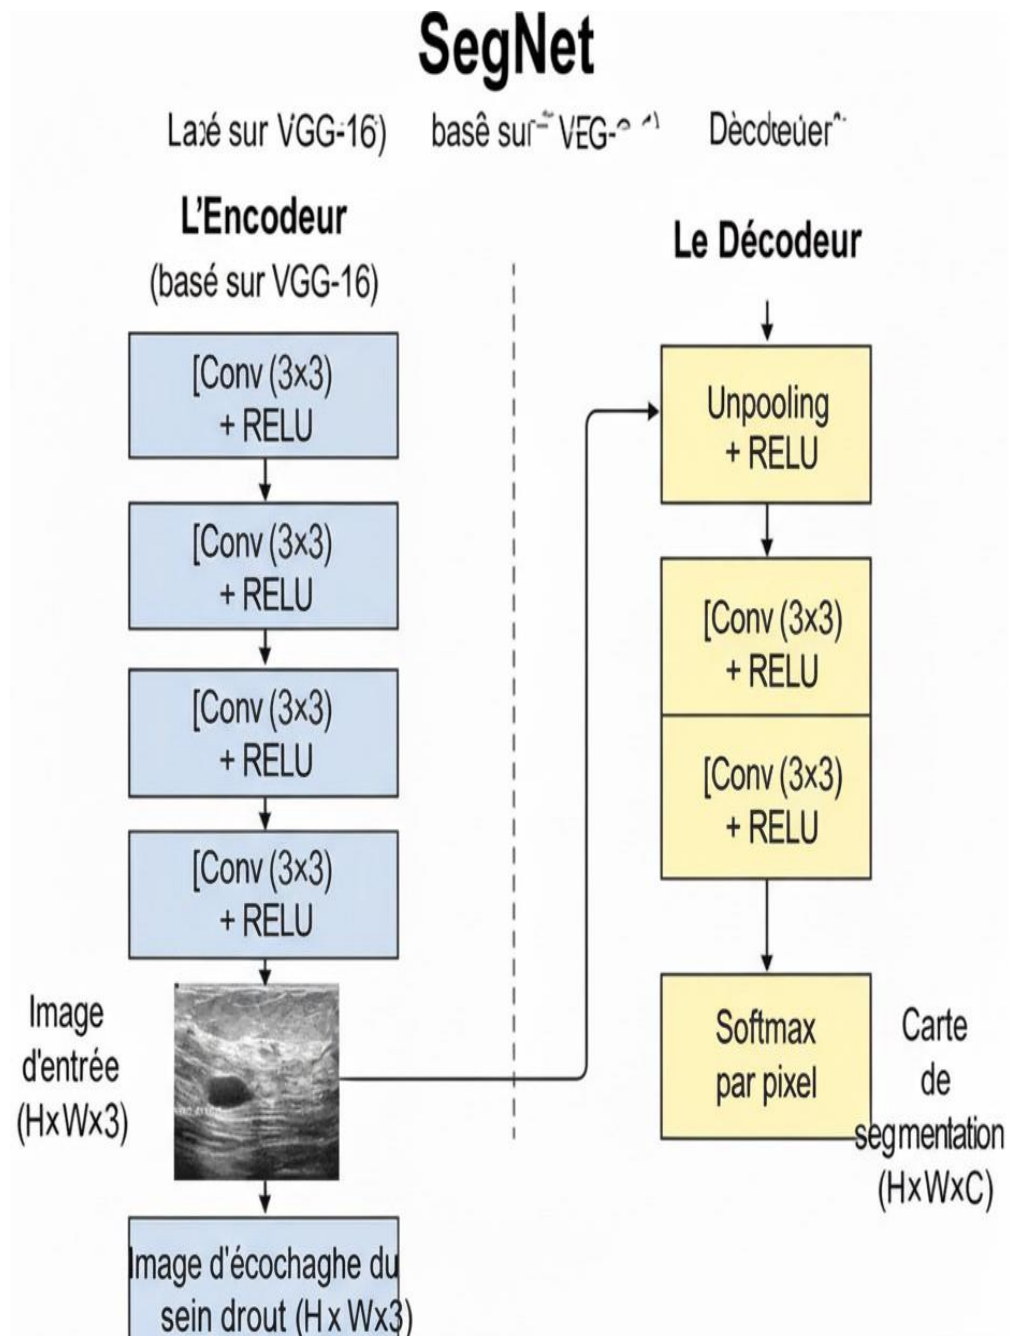


figure 11 : Exemple de segmentation sêmantique avec SegNet

**Tableau 3 : comparatif des architectures adaptées à l'analyse d'images médicales**

Modèle	Tâche Principale	Spécificité pour l'Imagerie Médicale	Idéal pour
U-Net	Segmentation	Skip connections pour combiner contexte et détails locaux, fonctionne bien avec peu de données annotées.	Segmentation de tumeurs, vaisseaux, organes.
SegNet	Segmentation	Utilise les indices de max-pooling pour une meilleure localisation spatiale lors du décodage.	Segmentation d'organes ou structures globales.
Mask R-CNN	Détection + Segmentation d'instance	Génère des masques binaires précis pour chaque instance d'objet détecté.	Segmentation de tumeurs multiples ou d'objets séparés.

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

### **II.4 l'État de l'Art : L'Impact des CNNs et de U-Net en Échographie**

#### **Mammaire :**

Dans cette section, nous nous concentrons sur les recherches récentes portant sur le développement de méthodes de segmentation d'images médicales échographiques appliquées à la détection du cancer du sein. Ces travaux visent principalement à améliorer la précision de la segmentation des lésions mammaires, en optimisant les performances des modèles à travers l'augmentation des coefficients de Dice et de Jaccard.

Ces deux indices sont des métriques essentielles pour évaluer la qualité du chevauchement entre les contours réels des tumeurs et ceux prévus par les algorithmes de segmentation. L'amélioration de ces scores reflète une meilleure détection des contours tumoraux, ce qui contribue directement à l'amélioration du taux de segmentation, donc à un diagnostic plus précis et fiable.

#### **1.U-Net Appliqué à la Segmentation des Tumeurs du Sein en Échographie (DBU-Net) :**

**Méthodologie et résultats :** Cet article de 2020 présente le DBU-Net, une version optimisée du modèle U-Net, spécialement conçue pour la délimitation précise des tumeurs dans les images échographiques du sein. La méthodologie innovante de DBU-Net repose sur une architecture à deux branches parallèles. Cette approche architecturale permet une extraction plus performante des informations discriminantes à différents niveaux de résolution et de contexte, ce qui est crucial pour la segmentation dans un environnement aussi complexe que les images échographiques. L'optimisation du U-Net via cette conception à double branche vise à améliorer significativement la capacité du modèle à identifier et à délimiter les contours des tumeurs, même en présence de bruit ou de faibles contrastes, contribuant ainsi à un diagnostic plus fiable.

Les auteurs indiquent des résultats remarquables pour le DBU-Net, confirmant l'efficacité accrue de cette variante améliorée du U-Net dans le contexte de la segmentation des tumeurs du sein en échographie. Les scores de Dicey, une métrique clé pour l'évaluation de la segmentation, dépassent fréquemment 0,90 (90 %), ce qui témoigne d'un excellent chevauchement entre les prédictions du modèle et les contours réels des tumeurs. Les valeurs de l'indice de Jaccard, qui mesurent la similarité et le recouvrement, sont supérieures à 0,80

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

(80 %), confirmant également la haute qualité de la segmentation. Bien que les valeurs exactes de précision (Accourcie), Recale (Sensibilité) et F1-score ne soient pas explicitement fournies dans le résumé fourni, les scores élevés de Dicey et de Jaccard sont de solides indicateurs d'une performance globale très satisfaisante. Un Dicey de 0,90 et un Jaccard de 0,80 impliquent généralement des valeurs de précision et de rappel également élevées, conduisant à un F1-score conséquent, attestant de la robustesse et de la fiabilité du DBU-Net pour cette application clinique. [76]

### **2.U-Net Amélioré pour la Segmentation des Masses Cancéreuses en Échographie du Sein :**

**Méthodologie et résultats :** Cet article de 2024 présente un travail axé sur une adaptation du modèle U-Net, spécifiquement destinée à la segmentation des masses tumorales dans les images échographiques mammaires. La méthodologie implique des améliorations structurelles du U-Net classique, visant à renforcer sa capacité à prendre en compte les caractéristiques spécifiques et souvent complexes des images ultrasonores, telles que le bruit, les artefacts et la variabilité des contours des lésions. Ces modifications sont conçues pour permettre au réseau d'extraire des informations plus discriminantes et de mieux délimiter les masses cancéreuses, contribuant ainsi à une détection plus fiable et précise.

Les résultats obtenus par cet U-Net amélioré démontrent la pertinence des modifications structurelles apportées pour accroître la fiabilité de la détection des lésions en échographie. La métrique clé de performance, le coefficient de Dicey, avoisine 0,90 (90 %), ce qui indique un très bon recouvrement entre les segments prédits par le modèle et les zones réelles des tumeurs. L'indice de Jaccard, une autre mesure importante de similarité, est fréquemment supérieur à 0,75 (75 %), ce qui confirme également la bonne qualité de la segmentation. Bien que le résumé ne fournisse pas explicitement les valeurs de précision (Accourcie), Recale (Sensibilité) et F1-score, les scores élevés de Dicey et Jaccard sont des indicateurs forts d'une performance globale solide. Un Dicey de 0,90 et un Jaccard de 0,75 suggèrent généralement que le modèle atteint un bon équilibre entre la capacité à détecter les vrais positifs et à minimiser les faux positifs et faux négatifs, se traduisant par des valeurs élevées pour ces métriques complémentaires. [77]

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

### **3.Architecture Avancée pour la Segmentation d'Images Échographiques du Sein (HMA-Net) :**

**Méthodologie et résultats :** Cet article très récent de 2025 introduit HMA-Net, une architecture innovante conçue pour la segmentation d'images échographiques du sein. La méthodologie de HMA-Net repose sur l'association d'un mélangeur hybride et d'un mécanisme d'attention multi-têtes. Cette stratégie avancée vise à améliorer considérablement l'extraction des caractéristiques pertinentes et à optimiser la fusion d'informations provenant de différentes parties de l'image. En combinant ces éléments, HMA-Net cherche à surmonter les défis inhérents aux images échographiques, tels que le bruit et les contours flous, pour une segmentation plus précise des masses. L'intégration de modules d'attention, dans la lignée des modèles de type U-Net améliorés, est un point clé pour atteindre une précision exceptionnelle.

Les résultats expérimentaux de HMA-Net sont particulièrement impressionnants, démontrant un potentiel significatif pour la segmentation d'images échographiques. L'indice de Jaccard (IoU) atteint un score remarquable de 98,04 %, ce qui indique un recouvrement quasi parfait entre les segments prédits par le modèle et les zones réelles des masses. Le coefficient de Dicey (DSC) est également exceptionnel, s'élevant à 99,01 %, confirmant une concordance extrêmement élevée. Ces performances soulignent le fort potentiel des modèles de type U-Net, lorsqu'ils sont améliorés par des modules d'attention sophistiqués comme ceux intégrés dans HMA-Net, pour offrir une précision de segmentation inégalée dans ce domaine clinique. Bien que les valeurs spécifiques de précision (Accourcie), Recale (Sensibilité) et F1-score ne soient pas détaillées dans le résumé, les scores extrêmement élevés de Dicey et Jaccard impliquent nécessairement des performances similaires pour ces métriques complémentaires, confirmant la fiabilité et l'efficacité de HMA-Net. [78]

### **4.U-Net Basé sur l'Attention pour la Segmentation des Images Échographiques du Sein :**

**Méthodologie et résultats :** Cet article très récent de 2025 propose une version du U-Net enrichie par un mécanisme d'attention multi-échelle pour la segmentation des images échographiques mammaires. La méthodologie innovante de cette approche permet au réseau de cibler dynamiquement les zones les plus pertinentes à travers différentes échelles de l'image. Cette capacité à se concentrer sur les informations critiques, qu'elles soient fines ou globales,

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

Améliore significativement la précision dans la détection des contours des lésions.  
L'intégration de modules d'attention vise

À affiner la capacité du modèle à distinguer les structures d'intérêt du bruit et des artefacts inhérents aux échographies, rendant la segmentation plus robuste et fiable.

Les résultats de cet U-Net basé sur l'attention montrent des performances solides, ce qui confirme l'efficacité des modules d'attention dans l'affinage des résultats de segmentation. Les indices de Jaccard sont généralement supérieurs à 0,80 (80 %), indiquant un bon recouvrement entre les segments prédits et les contours réels des tumeurs. Les coefficients de Dicey excèdent 0,89 (89 %), démontrant une excellente similarité. Bien que des valeurs exactes pour la précision (Accourcie), le Recale (Sensibilité) et le F1-score ne soient pas explicitement mentionnées dans le résumé, les scores élevés de Dicey et Jaccard sont de forts indicateurs d'une performance globale élevée pour ces métriques complémentaires. Ces résultats soulignent le potentiel prometteur de l'intégration de mécanismes d'attention multi-échelle pour améliorer la segmentation automatique des tumeurs du sein en échographie. [79]

### **5.Attention-Gated Multi RES U-Net :**

**Méthodologie et résultats :** La méthode Attention-Gâte Multi Resu-Net, proposée en 2024 pour la segmentation d'images échographiques du sein, repose sur une architecture de réseau de neurones convolutifs (CNN) multi-résolution innovante. Au cœur de cette approche se trouvent des portes d'attention, des modules adaptatifs conçus pour filtrer dynamiquement et cibler les régions d'intérêt à chaque niveau du réseau. Cette capacité à combiner de manière intelligente les informations fines et globales provenant des différentes couches du CNN est cruciale pour aborder les défis spécifiques des images échographiques, tels que la présence de bords flous et de contours diffus, améliorant ainsi significativement la segmentation. Les performances de cette méthodologie sont remarquables, avec un coefficient de Dicey de 0,93, un score de Jaccard (Ioug) d'environ 0,87, une précision (Accourcie) d'approximativement 96,0 %, un Recale (Sensibilité) de 93 %, une Spécificité de 99 % et un F1-score d'environ 0,93. Ces Résultats démontrent l'efficacité et la robustesse de l'Attention-Gâte Multi Resu-Net pour la segmentation précise des lésions dans les images échographiques mammaires. [80]

## Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art

### 6. Hybrid Attention Network (HANET) :

**Méthodologie et résultats :** La méthodologie du Hybrid Attention Network (HANet), proposée par Aslam et al. en 2025, représente une approche sophistiquée pour la segmentation. Ce modèle s'articule autour d'une base CNN robuste, spécifiquement un DenseNet-121, qui sert d'encodeur pour extraire des caractéristiques riches des images. Le décodeur du HANet est particulièrement innovant, intégrant une combinaison de modules d'attention multiples : l'attention spatiale globale pour capturer des dépendances à longue portée, l'encodage positionnel pour conserver les informations de localisation, et l'attention à produit scalaire pour pondérer l'importance des caractéristiques. Ce mécanisme d'attention multi-niveau permet au réseau de cibler avec une grande précision les zones d'intérêt, telles que les tumeurs, tout en incorporant des relations contextuelles complexes, ce qui est crucial pour une segmentation précise.

Les résultats obtenus par le HANet témoignent de son efficacité élevée. La métrique du Dicey, indiquant le chevauchement entre les prédictions et la vérité terrain, est supérieure à 0,91, signalant une excellente performance. Le coefficient de Jaccard (IoU), une autre mesure clé de similarité, atteint environ 0,86, confirmant la robustesse du modèle. En termes de précision globale (Accuracy), le HANet affiche un score d'environ 94,5 %. Le rappel (Sensibilité), qui mesure la capacité du modèle à identifier toutes les instances positives, est supérieur à 90 %, soulignant sa bonne détection des zones ciblées. Enfin, le F1-score, qui offre un équilibre entre la précision et le rappel, s'élève à environ 0,91, consolidant l'impression d'une performance globale solide et fiable de cette approche. [81]

### 7. EDCNN (Enhanced Deep CNN) :

**Méthodologie et résultats :** La méthodologie de l'Enhanced Deep CNN (EDCNN), présentée en 2023 dans ScienceDirect, propose une architecture de réseau de neurones convolutifs (CNN) profond spécifiquement conçue pour la double tâche de segmentation et de classification des tumeurs du sein. Cette approche tire parti de plusieurs innovations techniques pour optimiser ses performances. L'EDCNN intègre des couches convolutives optimisées qui permettent une

Extraction de caractéristiques plus efficace, ainsi que des blocs résiduels qui facilitent l'apprentissage en profondeur et atténuent le problème de la disparition du gradient. De plus,

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

Des techniques de normalisation avancées sont employées pour accroître la stabilité du modèle et le rendre plus

Robuste face au bruit intrinsèque des images échographiques. L'objectif est de fournir un modèle capable non seulement de délimiter précisément les zones tumorales, mais aussi de les classifier avec fiabilité.

Les résultats obtenus par l'EDCNN démontrent une performance solide dans les tâches de segmentation et de classification. Pour la segmentation, le coefficient de Dicey atteint environ 0,86, indiquant un bon recouvrement entre les segments prédits et la vérité terrain. Le score de Jaccard (Ioug) est d'environ 0,78, ce qui confirme une performance honorable en termes de similarité de forme et de position. En ce qui concerne les métriques de classification, la précision globale (Accourcie) est de 87,33 %, témoignant de la capacité du modèle à effectuer des prédictions correctes sur l'ensemble des données. Le recale (Sensibilité) s'élève à 85,33 %, indiquant que l'EDCNN est capable d'identifier une proportion significative des cas positifs. Enfin, le F1-score, qui représente une moyenne harmonique de la précision et du rappel, est de 86,00 %. Ces chiffres confirment que l'EDCNN est une solution prometteuse pour l'amélioration de la segmentation et de la classification du cancer du sein à partir d'images échographiques. [82]

### **8. MFFMT (Multi-Feature Fusion Multi-Task CNN) :**

**Méthodologie et résultats :** La méthodologie du Multi-Feature Fusion Multi-Task CNN (MFFMT), présentée par Li et al. En 2023, est une architecture innovante conçue pour la segmentation et la classification simultanées des images échographiques mammaires. Au cœur de cette approche multi-tâches, le modèle introduit deux composants clés : le module CLEP (Channel-wise and Local-wise Excitation and Pooling), qui intègre une fusion d'attention spatiale et de canal pour un recalibrage dynamique des caractéristiques, et un module de fusion multi-niveau (MFF). Ce dernier est chargé de combiner de manière efficace les informations extraites par les deux branches distinctes du réseau. Cette architecture avancée permet une Segmentation d'une grande précision tout en tenant compte du contexte clinique, offrant ainsi une compréhension plus complète et pertinente des images.

Les résultats obtenus par le MFFMT sont très performants et soulignent l'efficacité de son architecture. Le coefficient de Dicey pour la segmentation est d'environ 0,92, ce qui indique un

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

Excellent recouvrement entre les régions prédites et les régions réelles. Le score de Jaccard (Ioug) est également élevé, atteignant environ 0,85, confirmant la bonne qualité de la segmentation. En ce qui concerne les métriques de classification, la précision globale (Accourcie) se situe autour de 93,0 %, démontrant la robustesse du modèle dans ses prédictions. Le recale (Sensibilité) est supérieur à 90 %, ce qui est crucial pour la détection de toutes les instances pertinentes, en particulier dans un contexte médical. Enfin, le F1-score est supérieur à 0,90, consolidant l'impression d'une performance globale équilibrée et supérieure de la méthode MFFMT pour la segmentation et la classification des images échographiques mammaires. [83]

### **9.Two-Stage CNN avec Masque Tumoral :**

**Méthodologie et résultats :** La méthodologie du modèle Two-Stage CNN avec Masque Tumoral, proposée par Long et al. En 2023, se distingue par son approche séquentielle en deux étapes pour le diagnostic des images échographiques mammaires. La première étape implique une segmentation des tumeurs à l'aide d'un réseau de neurones convolutifs (CNN) dédié, générant ainsi un masque précis de la zone d'intérêt. Ce masque tumoral, qui incorpore des connaissances anatomiques détaillées extraites du processus de segmentation, est ensuite concaténé avec l'image originale. Dans la seconde étape, cette combinaison de l'image et de son masque tumoral est alimentée à un second CNN spécifiquement entraîné pour la tâche de classification. Cette stratégie en deux temps permet de renforcer considérablement la fiabilité du diagnostic en intégrant des informations spatiales et anatomiques explicites, guidant ainsi le réseau de classification vers une meilleure compréhension des caractéristiques pertinentes pour le diagnostic.

Les résultats obtenus par ce modèle Two-Stage CNN sont très prometteurs, soulignant l'efficacité de l'intégration du masque tumoral. Pour la segmentation, le coefficient de Dicey atteint environ 0,90, indiquant un très bon chevauchement entre les prédictions et les contours Réels des tumeurs. Le score de Jaccard (Ioug) est également élevé, à environ 0,83, confirmant la précision de la segmentation. En ce qui concerne la tâche de classification, la précision globale (Accourcie) est d'environ 92,4 %, démontrant la capacité du modèle à classer

Correctement un grand nombre de cas. Le recale (Sensibilité) est d'environ 93 %, ce qui est particulièrement important pour s'assurer que la majorité des cas positifs sont correctement

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

Identifiés. Enfin, le F1-score, qui représente un équilibre entre précision et rappel, est également d'environ 93 %. L'ensemble de ces métriques atteste de la performance globale robuste et de la fiabilité de cette approche en deux étapes pour l'amélioration du diagnostic du cancer du sein par échographie. [84]

### **10.CNN + Swin Transformer avec Masques Prioritaires :**

**Méthodologie et résultats :** La méthodologie "CNN + Swin Transformer avec Masques Prioritaires", publiée en 2024 dans SCI Open, représente une avancée significative dans la segmentation. Cette approche hybride tire parti des forces complémentaires de deux architectures de réseaux de neurones profonds. Elle combine un CNN VGG16, reconnu pour son efficacité dans la capture de détails locaux et de caractéristiques fines, avec un Swin Transformer. Ce dernier excelle dans la modélisation des relations globales et des dépendances à longue portée au sein des images. La particularité de cette méthode réside dans l'utilisation d'un masque tumoral généré automatiquement en entrée. Ce masque sert d'indice spatial prioritaire, guidant le modèle vers les régions d'intérêt et permettant une fusion plus intelligente des informations locales et globales. L'objectif est d'exploiter cette synergie pour améliorer considérablement la précision de la segmentation, notamment dans des contextes complexes où la délimitation précise des objets est cruciale.

Les résultats obtenus par cette méthode sont exceptionnellement élevés, témoignant de l'efficacité de l'intégration du masque prioritaire et de la fusion CNN-Transformer. Le coefficient de Dicey atteint une valeur impressionnante d'environ 0,98, indiquant une quasi-parfaite superposition entre les segments prédits et la vérité terrain. Le score de Jaccard (Ioug) est également très élevé, à environ 0,96, confirmant l'excellente qualité de la segmentation. En termes de classification, la précision (Accourcie), le recale (Sensibilité) et le F1-score affichent tous des performances remarquables d'environ 98,70 % et 98,72 % respectivement. Ces chiffres soulignent la capacité du modèle à identifier et à délimiter avec une grande exactitude les

Régions d'intérêt, tout en minimisant les erreurs de classification. De plus, la valeur de l'AUC (Area Under the Curve) de 0,9982 corrobore la capacité discriminante exceptionnelle du modèle, le rendant extrêmement fiable pour les applications de segmentation et de classification. [85]

## **Chapitre I I: le rôle de l'informatique dans l'analyse des images médicales et L état de l'art**

### **II.5 Conclusion :**

Dans ce chapitre, nous avons mis en évidence le rôle essentiel de l'ordinateur dans l'amélioration de l'analyse et de la segmentation des images médicales, notamment dans le cadre de la détection des anomalies mammaires.

Nous avons d'abord exploré les méthodes classiques de segmentation, telles que celles basées sur le seuil, les régions, les contours, qui ont permis de poser les bases de l'analyse automatique. Bien que simples à mettre en œuvre, ces approches souffrent de limitations en termes de précision et de robustesse, notamment face aux défis spécifiques des images échographiques (bruit, faible contraste, bords flous).

Nous avons ensuite détaillé les avancées majeures apportées par l'intelligence artificielle, et plus particulièrement par l'apprentissage profond. Les réseaux de neurones convolutifs (CNN), et leurs architectures adaptées comme le U-Net, le SegNet ou encore le Mask-CNN, ont permis des progrès significatifs en offrant une segmentation plus précise, plus stable et mieux adaptée aux particularités des images médicales.

En conclusion, les travaux les plus récents, abordés dans l'état de l'art, confirment que les architectures U-Net et leurs variantes enrichies (attention multi-têtes, multi-échelle, branches parallèles...) jouent aujourd'hui un rôle central dans la segmentation biomédicale. Leur capacité à extraire des informations à la fois globales et locales, tout en gérant les complexités visuelles des images échographiques, en fait des outils incontournables dans les systèmes modernes d'aide au diagnostic.

---

---

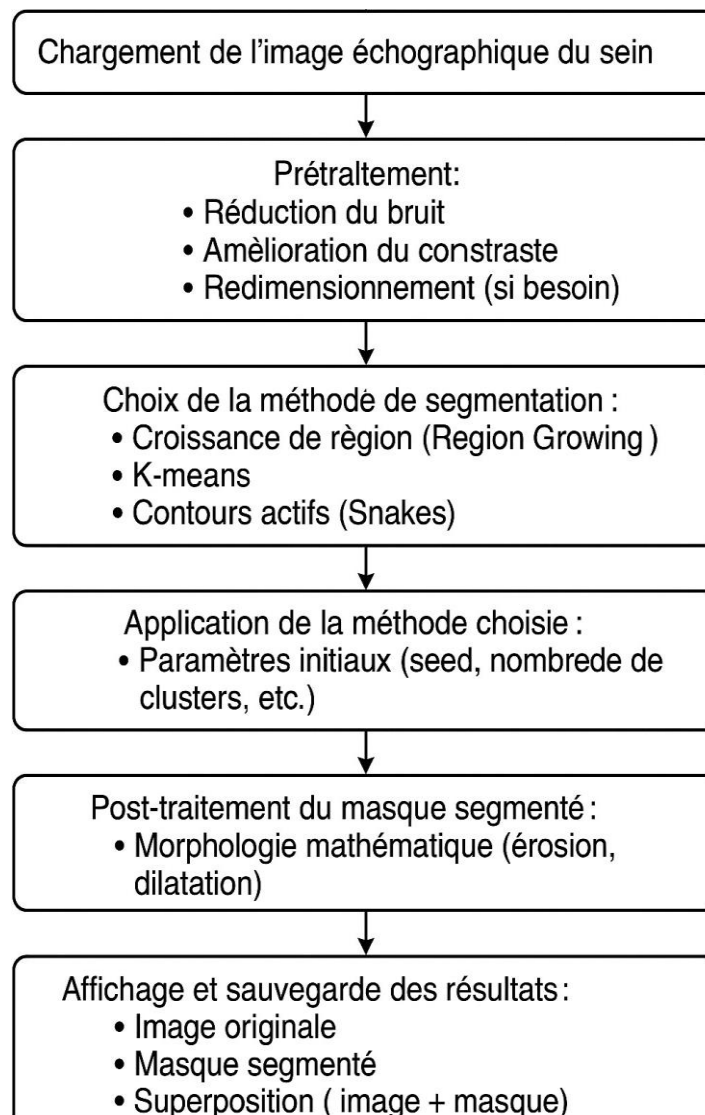
# **CHAPITRE III : Méthodologie et Implémentation**

---

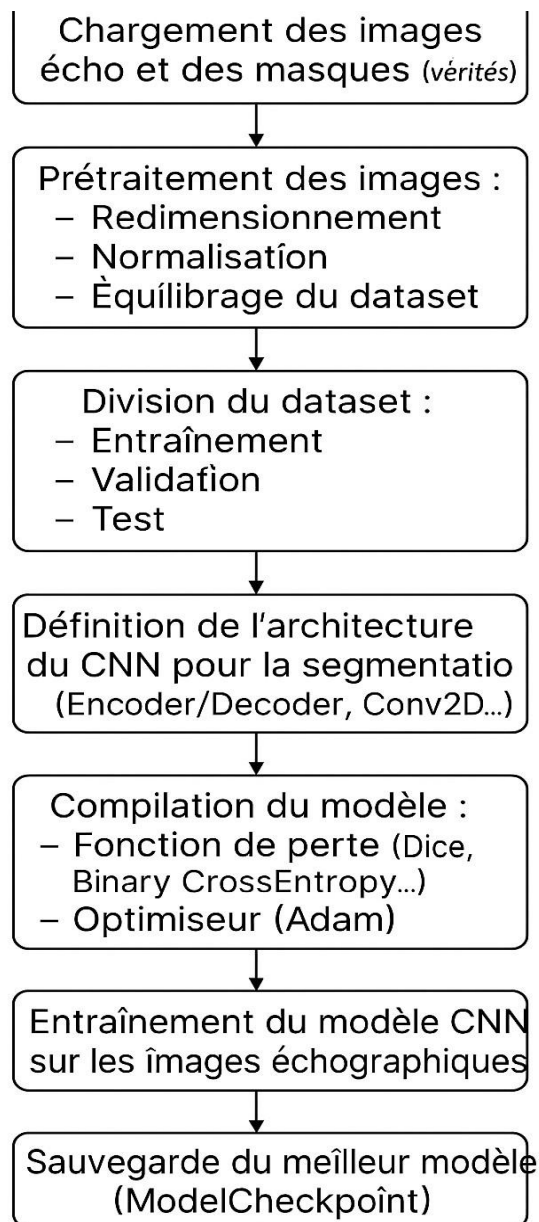
---

**III.1 Introduction :**

Le diagnostic précoce du cancer du sein est crucial pour améliorer les taux de survie des patients. L'échographie mammaire est une modalité d'imagerie non invasive, largement utilisée pour la détection et l'évaluation des anomalies. Cependant, l'interprétation de ces images reste un défi en raison du bruit (speckle) et de la variabilité des caractéristiques des tumeurs. Pour surmonter ces difficultés, nous présentons la méthodologie adoptée pour la segmentation des lésions mammaires à partir d'images échographiques, avec un pipeline structuré de traitement d'image pour la segmentation automatique ou semi-automatique des lésions, permettant une délimitation précise des tumeurs et une aide à la prise de décision clinique. Dans ce chapitre, nous décrivons d'abord les méthodes classiques de segmentation d'images médicales mises en œuvre dans le cadre de notre projet, notamment la croissance de région, la méthode des k-means et les contours actifs, toutes développées sous MATLAB. Nous abordons ensuite la segmentation par apprentissage profond à l'aide des réseaux de neurones convolutifs (CNN), avec un accent particulier sur l'architecture U-Net, codée en Python. Cette partie inclut également la présentation des équations mathématiques des mesures de performance utilisées, telles que le coefficient de Dice, l'indice de Jaccard, la précision, le rappel, la spécificité et le score F1, en mettant en lumière leur rôle dans l'évaluation des modèles de segmentation d'images médicales et leur contribution à l'amélioration de la fiabilité du diagnostic assisté par ordinateur. Le chapitre est structuré autour des principales étapes suivantes : la présentation du jeu de données, les prétraitements appliqués, la description du modèle U-Net, les paramètres d'entraînement, ainsi que les métriques d'évaluation permettant de mesurer les performances de chaque approche..



**figure 12 : Diagramme de Segmentation des Lésions Mammaires  
par les méthodes classiques**



**figure 13 : Diagramme de Segmentation des Lésions Mammaires par la méthode cnn**

## III.2 l'explication de l'algorithme pour les méthodes classiques de la segmentation :

### 1. Chargement de l'image

Cette étape initiale consiste à charger l'image échographique en mémoire. L'image est représentée comme une matrice de pixels, où chaque pixel (dans le cas d'une image en niveaux de gris 8 bits) a une valeur d'intensité entre 0 (noir) et 255 (blanc).

- **Détail technique :** Pour une image en niveaux de gris, elle est représentée par une matrice  $I$  de dimensions  $(H,L)$ , où  $H$  est la hauteur et  $L$  la largeur. La valeur de chaque pixel  $I(y,x)$  varie typiquement entre 0 et 255.

### 2. Prétraitement

Cette phase est essentielle pour optimiser l'image avant la segmentation.

- **Réduction du bruit (Débruitage):**
  - **Filtre Médian :** Remplace la valeur d'un pixel par la médiane des valeurs de ses voisins.
  - **Formule :**  $I_{\text{filtré}}(y, x) = \text{median}I(i, j)$  pour  $(i,j)$  dans le voisinage de  $(y,x)$ .
  - **Filtre Gaussien :** Adoucit l'image en convoluant avec un noyau Gaussien.
  - **Formule (Noyau 2D) :**  $G(x, y) = \frac{1}{\pi 2\sigma^2} e^{-(x^2+y^2) / 2\sigma^2}$  convolution est :

$$I_{\text{filtré}} = I * G$$

### Amélioration du contraste:


.Égalisation d'histogramme : Utilise la fonction de répartition (CDF) de l'histogramme de l'image pour transformer les intensités

Formule : Soit  $p(i)$  la probabilité d'un niveau de gris  $i$ . La fonction de transformation est :  $s(k) = \text{round}(255 \times \sum_{i=0}^k p(i))$  pour  $k=0,1,\dots,255$ . Chaque pixel  $I(y,x)$  de valeur  $k$  est remplacé par la nouvelle valeur  $s(k)$ .

**Redimensionnement (si nécessaire):** La taille de l'image peut être réduite pour accélérer les traitements ultérieurs.

### 3.Choix de la Méthode de Segmentation

#### A. le principe de segmentation par la méthode de Croissance de région :



Ce code implémente une méthode classique de segmentation basée sur la croissance de région. L'utilisateur sélectionne une image échographique ainsi que son masque réel (*ground truth*), puis clique sur un point de départ situé à l'intérieur de la tumeur. L'algorithme agrandit alors progressivement la région autour de ce point en intégrant les pixels voisins dont les valeurs d'intensité sont similaires, selon un seuil de tolérance prédéfini (fixé ici à 25). Une opération de dilatation morphologique est ensuite appliquée afin d'élargir légèrement la zone segmentée. Enfin, la performance de la segmentation est évaluée à l'aide de plusieurs métriques : l'indice de Jaccard, le coefficient de Dice, la précision, le rappel, le score F1 et l'exactitude (*accuracy*). Tous les résultats sont affichés à l'écran et sauvegardés automatiquement pour une analyse ultérieure.


#### Formulation :

Choisir un pixel seed  $s$  de coordonnées  $(y_s, x_s)$ .

Définir un critère d'homogénéité (ex :

$$| I(\text{pixel voisin}) - I(\text{r\'egion moyenne}) | < \text{Seuil}$$

Répéter l'ajout de pixels voisins respectant le critère jusqu'à convergence.



### B. le principe de segmentation par la méthode de K-means :

Ce code MATLAB implémente un pipeline de segmentation d'images destiné à la détection de tumeurs. L'utilisateur commence par sélectionner une image médicale ainsi que son masque de vérité terrain (*ground truth*), puis définit manuellement une région d'intérêt (ROI) sur l'image originale. Les pixels de cette région sont ensuite segmentés en deux groupes (tumeur/fond) à l'aide de l'algorithme *k-means*, en considérant que le cluster le plus sombre correspond à la tumeur. Une fois cette segmentation initiale obtenue, des opérations morphologiques telles que l'érosion, la dilatation et le remplissage des trous sont appliquées afin d'affiner le masque généré. La performance de la segmentation est ensuite rigoureusement évaluée à l'aide de plusieurs métriques : l'indice de Jaccard, le coefficient de Dice, l'exactitude (*accuracy*), la précision, le rappel et le score F1. L'ensemble des résultats, y compris les visualisations intermédiaires, les superpositions et les masques finaux, est affiché et sauvegardé pour permettre une analyse qualitative et quantitative approfondie.

#### Formulation Mathématique :


Choisir K centroïdes initiaux,  $\mu_k$ .

**Étape d'assignation :** Assigner chaque pixel  $x_i$  au cluster  $C_k$  dont le centroïde  $\mu_k$  est le plus proche (distance Euclidienne).

$$C_k = \{x_i: \|x_i - \mu_k\| \leq \|x_i - \mu_j\| \text{ pour tout } j \neq k\}$$

**Étape de mise à jour :** Recalculer les centroïdes.

$$\mu_k = \frac{1}{|C_k|} \sum_{x_i \in C_k} x_i$$



### C. le principe de segmentation par la méthode de-contour actif :

Ce code MATLAB réalise la segmentation d'une image échographique à l'aide de la méthode des contours actifs, basée sur le modèle de Chan-Vese. Le processus commence par la sélection de l'image échographique et de son masque de vérité terrain (*ground truth*), suivie d'une conversion en niveaux de gris et d'une amélioration du contraste. L'utilisateur est ensuite invité à cliquer sur le centre approximatif de la tumeur, point à partir duquel un masque initial rectangulaire est généré. La segmentation est ensuite effectuée à l'aide de la fonction *activecontour*, utilisant ce masque comme point de départ, puis une dilatation morphologique est appliquée pour affiner le résultat.

Le code intègre également une logique adaptative : si l'indice de Jaccard obtenu après la première itération est jugé insuffisant, la segmentation est automatiquement relancée avec un masque initial élargi, afin d'améliorer la couverture de la lésion. La performance finale est ensuite évaluée de manière rigoureuse en comparant le masque segmenté au masque réel à l'aide de différentes métriques d'évaluation : l'indice de Jaccard, le coefficient de Dice, la justesse (*accuracy*), la précision, le rappel et le score F1. L'ensemble des résultats, incluant les images originales, les masques générés, les superpositions et les comparaisons visuelles, est affiché et sauvegardé automatiquement dans un dossier sélectionné par l'utilisateur, permettant une analyse à la fois quantitative et qualitative des performances de la méthode.

#### Formulation Mathématique (Énergie) :

L'énergie totale *Esnake* d'un contour :  $v(s) = (x(s), y(s))$  est la somme d'une énergie interne ( $E_{int}$ ) et d'une énergie externe ( $E_{ext}$ ) :  $E_{snake} = \int [E_{int}(v(s)) + E_{ext}(v(s))] ds$

**Énergie Interne** : Contrôle la régularité et la courbure du contour.

$$E_{int} = \alpha(s) | dv/ds | * 2 + \beta(s) | d * 2v/ds * 2 | * 2$$

**Énergie Externe** : Attire le contour vers les bords de l'image.

$$E_{ext} = -\gamma | \nabla(G\sigma * I(x, y)) | * 2$$

#### 4. Post-traitement (Morphologie Mathématique)

Le masque de segmentation obtenu est souvent imparfait. Les opérations de morphologie mathématique permettent de le nettoyer.

Érosion ( $\ominus$ ) : Rétrécit les régions, supprime les petits objets

$$A \ominus S = \{z \mid (S)z \subseteq A\}.$$

Dilatation ( $\oplus$ ) : Élargit les régions, comble les petits trous.

$$A \oplus S = \{z \mid (S^{\wedge})z \cap A \neq \emptyset\}$$

#### 5. Affichage et Sauvegarde des Résultats




figure 14 : la présentation pour les étapes pour la segmentation par croissant des régions




figure 15 : la présentation pour les étapes pour la segmentation par K-means




figure 16: la présentation pour les étapes pour la segmentation par contour actif

### III.3 Expliquer les détails de la technologie d'apprentissage profond

**Cnn(u-net) :**



#### III.3.1 Détailler le choix et la description de l'architecture d'apprentissage profond :

Je l'ai utilisé U-Net parce que :

1. Efficacité avec des données limitées : Le U-Net est reconnu pour ses bonnes performances même avec des jeux de données de petite taille, ce qui est souvent le cas en imagerie médicale.
2. Capture du contexte local et global : Ses connexions résiduelles (skip connections) lui permettent de combiner des caractéristiques à haute résolution provenant de la partie descendante (contracting path) avec des caractéristiques sémantiques à basse résolution de la partie ascendante (expanding path).
3. Performance avérée en segmentation d'images médicales : C'est une architecture largement adoptée et très efficace dans ce domaine.

#### III.3.2 Description de l'architecture spécifique:

Le modèle utilisé est un U-Net modifié, conçu pour la segmentation des tumeurs du sein sur des images échographiques de taille  $256 \times 256$  pixels. L'architecture comporte un encodeur composé de cinq niveaux, chacun constitué de deux couches de convolution (Conv2D) suivies de normalisation par lot (BatchNormalization), d'une activation ReLU, d'une couche de max pooling (MaxPooling2D) et d'un dropout pour limiter le surapprentissage. Le nombre de filtres double à chaque niveau, passant de 16 à 256. Ensuite, les données passent par une couche centrale (bottleneck) avec 256 filtres. Le décodeur comprend également cinq niveaux, utilisant des couches de déconvolution (Conv2DTranspose) pour augmenter la résolution, suivies de la concaténation avec les cartes de caractéristiques correspondantes de l'encodeur (skip connections), puis de deux convolutions avec BatchNormalization et ReLU à chaque niveau.

Le nombre de filtres diminue progressivement jusqu'à 16. Enfin, une couche de sortie Conv2D avec une taille de noyau  $1 \times 1$ , un seul filtre et une activation sigmoïd permet de produire un masque binaire représentant la région tumorale. Le modèle contient environ 2 164 595 paramètres entraînaibles, pour une taille d'environ 8,26 Mo.

**Tableau 4 : Résumé des caractéristiques de l'architecture U-Net modifiée**

Élément	Détail
Architecture	U-Net modifié
Entrée	256×256×3 (images échographiques)
Niveaux encoder/décoder	5 niveaux chacun
Filtres	16→32→64→128→256 (descente), puis inversement en montée
Couches	Conv2D, BatchNorm, ReLU, Dropout, MaxPooling / Conv2DTranspose
Sortie	Conv2D (1 filtre), activation sigmoïd
Paramètres totaux	2,164,595
Taille mémoire	8.26 MB

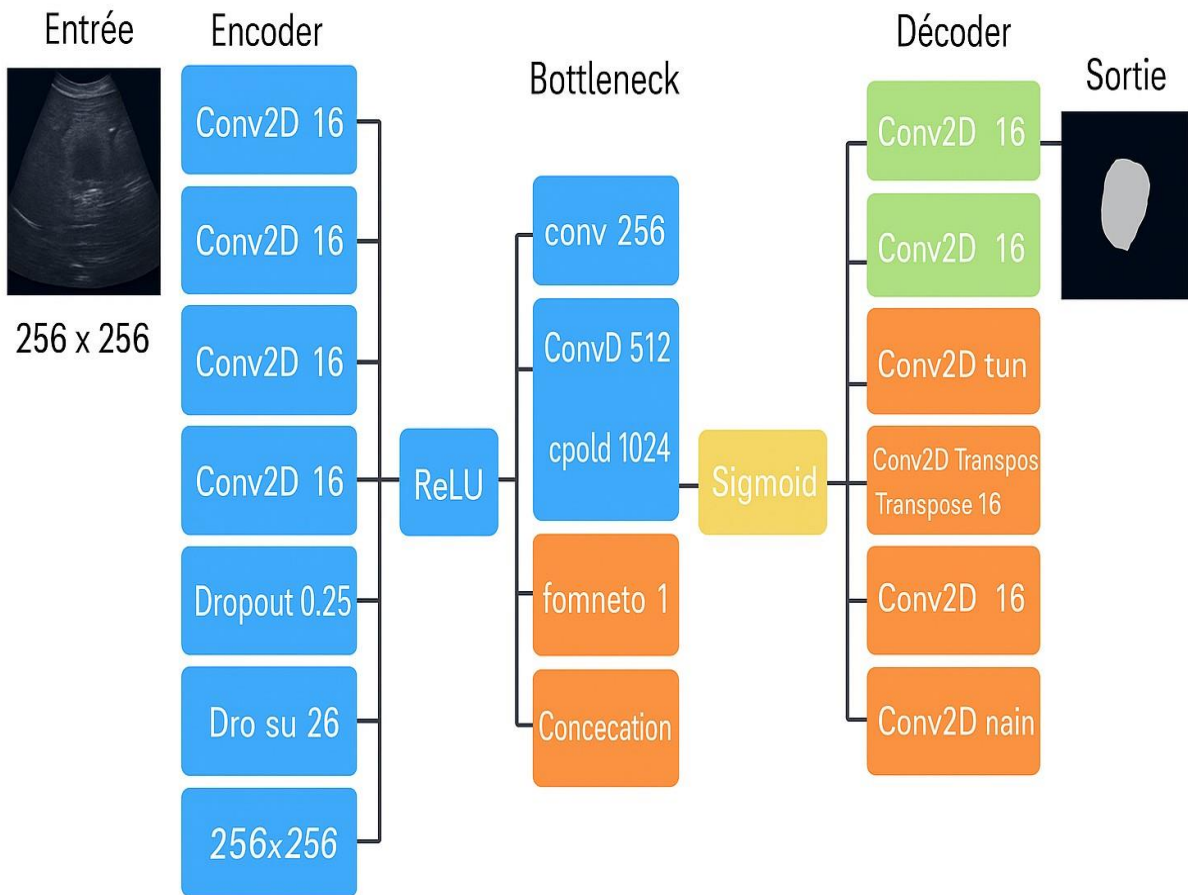


figure 17 : Schéma de l'architecture U-Net modifiée utilisée pour la segmentation des tumeurs mammaires



### III.3.3 Description du base de Données (Dataset) :

#### 1. Données :

Les données utilisées proviennent d'images échographiques du sein acquises auprès de femmes âgées de 25 à 75 ans. La collecte a été réalisée en 2018 auprès de 600 patientes. Le jeu de données comprend un total de 780 images au format PNG, d'une taille moyenne de  $500 \times 500$  pixels. Ces images sont réparties en trois catégories : 437 images bénignes, 210 images malignes et 133 images normales. Chaque image est associée à une image de référence (masque de vérité terrain) permettant l'évaluation des performances de segmentation. Des exemples illustratifs des images originales.[86]

#### 2.Collecte de données :

Les images échographiques en niveaux de gris ont été collectées à l'hôpital Baheya et enregistrées au format DICOM. Le processus de collecte et d'annotation s'est étendu sur environ une année. Initialement composé de 1 100 images, le jeu de données a été réduit à 780 après les étapes de prétraitement, afin d'éliminer les informations non pertinentes. Les acquisitions ont été réalisées à l'aide des systèmes LOGIQ E9 et LOGIQ E9 Agile, offrant une résolution de  $1280 \times 1024$  pixels et utilisant des transducteurs de 1 à 5 MHz montés sur une sonde linéaire ML6-15-D Matrix.

#### 3. Prétraitement :

Afin de rendre le jeu de données exploitable, plusieurs opérations de préparation ont été effectuées. Les images dupliquées ont été supprimées et les annotations incorrectes corrigées par des radiologues de l'hôpital Baheya. Les images initialement au format DICOM ont été converties en PNG à l'aide d'un convertisseur dédié [87]. Après cette phase de nettoyage, le nombre total d'images échographiques a été réduit à 780, réparties en trois catégories : normales, bénignes et malignes. Les images ont été recadrées à l'aide de l'outil *Fast Photo Crop* [88] afin d'éliminer les zones non pertinentes. Enfin, l'annotation correspondante a été ajoutée au nom de chaque image, et l'ensemble du jeu de données a été vérifié par des radiologues spécialisés.

**4.Vérité fondamentale :**

La génération des masques de vérité terrain (contours des lésions) a été réalisée afin de rendre le jeu de données exploitable. Cette étape a été effectuée sous MATLAB [89] à l'aide d'une segmentation manuelle libre pour chaque image individuellement. Trois dossiers distincts ont été créés selon les catégories de tumeurs mammaires : normales, bénignes et malignes. Chaque dossier contient les images correspondant à sa classe. Les noms des fichiers intègrent la catégorie et le numéro de l'image, tandis que les masques portent le même nom que l'image échographique avec le suffixe « \_mask » ajouté à la fin.

**5.Considérations éthiques :**

Les chercheurs ont veillé à garantir la protection de la vie privée des patientes et la confidentialité des données médicales. Ainsi, les participantes et l'hôpital ont été dûment informés des objectifs de l'étude. De plus, l'ensemble des données recueillies a été anonymisé, assurant que l'identité des patientes et les informations relatives à leur état de santé demeurent strictement confidentielles.

Cependant, cette base de données présente certaines limites :

- Taille du dataset limitée (780 images), ce qui augmente le risque de surapprentissage lors de l'entraînement des modèles.
- Segmentation manuelle, dépendante de l'expertise du radiologue, pouvant introduire une variabilité ou une erreur humaine.
- Différences entre appareils d'acquisition et recadrage des images, susceptibles d'entraîner une perte d'informations et un manque d'uniformité dans les données.

**Remarque : Dans notre travail, nous nous concentrons uniquement sur les images de tumeurs malignes et bénignes.**

### III.3.4 Pré-traitement des Données :

Afin de préparer les images à l'entraînement du modèle de segmentation, plusieurs étapes de pré-traitement ont été rigoureusement appliquées. Tout d'abord, chaque image échographique ainsi que son masque associé ont été redimensionnés à une taille uniforme de  $256 \times 256$  pixels, ce qui garantit une cohérence des dimensions à l'entrée du modèle U-Net. Ensuite, une normalisation des intensités de pixels a été effectuée en divisant les valeurs par 255, ramenant ainsi les intensités dans l'intervalle  $[0, 1]$ , ce qui facilite la convergence lors de l'entraînement. Afin de renforcer la robustesse du modèle face à la variabilité des données médicales et de réduire le risque de surapprentissage, une augmentation des données a été mise en œuvre. Celle-ci inclut diverses transformations aléatoires telles que la rotation, le retournement horizontal et vertical, le zoom, ainsi que des ajustements de luminosité et de contraste. De plus, dans certains cas, des filtres de réduction du bruit (notamment le speckle noise présent dans les images échographiques) ont été appliqués afin d'améliorer la lisibilité des structures pertinentes tout en préservant les contours tumoraux. Ces étapes de pré-traitement ont été essentielles pour améliorer la qualité et la diversité des données d'entrée, augmentant ainsi la capacité de généralisation du modèle de segmentation.

### III.3.5 Paramètres d'entraînement du Modèle :

L'entraînement du modèle de segmentation U-Net a été réalisé en utilisant la fonction de perte Binary Cross-Entropy (BCE). Cette fonction est particulièrement adaptée aux tâches de segmentation binaire comme celle du cancer du sein, où chaque pixel de l'image doit être classé comme appartenant ou non à une région tumorale. Toutefois, dans certains cas, l'utilisation d'une fonction de perte hybride, combinant la BCE et la Dice Loss, peut s'avérer pertinente afin de mieux gérer le déséquilibre entre les classes et de maximiser la similarité spatiale entre le masque prédit et le masque réel.

L'optimiseur Adam a été employé pour l'entraînement du réseau en raison de sa capacité à ajuster dynamiquement le taux d'apprentissage de chaque paramètre, ce qui assure une convergence rapide et stable. Le taux d'apprentissage initial a été fixé à 0,001, avec une stratégie de réduction automatique (learning rate decay) lorsque la perte sur l'ensemble de

validation stagnait pendant plusieurs époques. Aucun paramètre de momentum explicite n'a été défini, puisque Adam intègre déjà une estimation du moment.

Le modèle a été entraîné pendant 50 époques, permettant d'atteindre une stabilisation des performances sans surapprentissage. La taille du batch a été fixée à 16 images par itération, représentant un bon compromis entre rapidité de calcul et stabilité de l'apprentissage.

L'environnement de développement est basé sur le langage Python, en utilisant les frameworks TensorFlow 2.x et Keras pour la conception et l'entraînement du modèle. L'entraînement a été effectué sur la plateforme Kaggle, qui offre un environnement GPU dédié permettant d'accélérer considérablement les calculs matriciels nécessaires aux réseaux de neurones profonds. Les bibliothèques principales utilisées incluent NumPy, OpenCV, Matplotlib, scikit-learn pour les métriques, ainsi que Tkinter pour la conception de l'interface graphique utilisateur.

### **III.3.6 modèle évaluation:**

Le modèle a été entraîné sur un total de 50 époques, avec une stabilisation notable à partir de la 35<sup>e</sup> époque, où les courbes de précision et de perte deviennent quasi horizontales, traduisant une convergence complète et l'absence de surapprentissage.

L'évaluation des performances repose sur les métriques classiques du Deep Learning, telles que l'accuracy, la précision, le rappel et le F1-score. Ces indicateurs ont permis d'apprécier la qualité de la classification et la capacité du modèle à distinguer efficacement les différentes catégories d'images.

Les courbes d'apprentissage montrent une stabilité exemplaire, avec une perte minimale observée autour de la 18<sup>e</sup> époque, confirmant une convergence rapide et stable du modèle. La courbe ROC et la matrice de confusion mettent en évidence une cohérence entre les phases d'entraînement et de validation, démontrant la robustesse et la fiabilité du modèle, ce qui le rend apte à une application clinique potentielle.

### III.3.7 Critères d'arrêt et validation :

En revanche, aucun mécanisme d'arrêt anticipé (*early stopping*) n'a été mis en œuvre dans le cadre de ce travail. L'entraînement a été conduit sur un nombre fixe de 50 époques, sans interruption automatique en cas de stagnation de la fonction de perte (*loss*) sur l'ensemble de validation. Les courbes montrent d'ailleurs que le modèle atteint son plateau de performance maximal bien avant la fin du processus (autour de l'époque 35). L'intégration future d'un tel mécanisme pourrait représenter une amélioration pertinente afin de limiter le risque de surapprentissage (*overfitting*) et d'optimiser davantage la généralisation du modèle en réduisant le temps de calcul..

## III.4 Métriques d'évaluation pour la segmentation d'images médicales :

### III.4.1 Discussion sur les métriques de performance en segmentation d'images médicales

L'évaluation des performances d'un algorithme de segmentation, notamment en imagerie échographique du sein, repose sur plusieurs métriques quantitatives qui permettent de mesurer la qualité des résultats obtenus. Ces indicateurs sont essentiels pour juger de la fiabilité et de l'applicabilité clinique d'un modèle de segmentation.

Le coefficient de Dice est l'une des métriques les plus couramment utilisées. Il mesure la similarité entre la région prédite et la région réelle, en évaluant le chevauchement entre les deux. Une valeur proche de 1 indique une très bonne concordance. Cette métrique est particulièrement adaptée pour évaluer des structures bien délimitées, telles que les contours tumoraux.

$$Dice = \frac{2 \cdot VP}{2 \cdot VP + FP + FN}$$

L'indice de Jaccard, également connu sous le nom d'Intersection over Union (IoU), est une autre mesure de similarité. Légèrement plus stricte que le coefficient de Dice, elle compare la taille de l'intersection entre les zones prédite et réelle à la taille de leur union. Elle est fréquemment utilisée pour valider la robustesse des algorithmes, notamment lorsqu'on cherche à éviter les surestimations.

$$Jaccard = \frac{VP}{VP + FP + FN}$$

L'exactitude (*accuracy*), ou taux de pixels correctement classés, fournit une mesure globale des performances du modèle. Toutefois, cette métrique peut être trompeuse dans les cas de déséquilibre des classes, par exemple lorsque la tumeur occupe une très petite portion de l'image : un modèle ignorant complètement cette tumeur pourrait malgré tout afficher une exactitude élevée.

$$\mathbf{Accuracy} = \frac{VP + VN}{VP + VN + FP + FN}$$

La sensibilité, ou rappel (*recall*), est une métrique fondamentale en contexte médical. Elle mesure la capacité du modèle à détecter correctement les régions pathologiques. Une sensibilité faible signifie que des lésions pourraient être omises, ce qui est inacceptable dans un cadre de dépistage.

La spécificité, quant à elle, mesure la capacité du modèle à reconnaître les zones saines. Elle est utile pour éviter les faux positifs, qui peuvent conduire à des examens complémentaires ou à des traitements non nécessaires.

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

La précision (*precision*) évalue la proportion de pixels identifiés comme pathologiques qui sont effectivement des lésions. Elle permet donc d'estimer la fiabilité des détections positives, ce qui est crucial pour réduire le risque de surdiagnostic.

$$\mathbf{Precision} = \frac{VP}{VP + FP}$$

Enfin, le score F1 combine à la fois la précision et la sensibilité, fournissant ainsi une mesure équilibrée des performances. Il est particulièrement utile dans les situations où les classes sont déséquilibrées et lorsqu'une comparaison globale entre plusieurs modèles est nécessaire.

$$\mathbf{F1} = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$$

En pratique clinique, aucune métrique ne doit être interprétée isolément. Leur analyse conjointe permet d'adapter l'évaluation en fonction des objectifs : maximiser la sensibilité dans les cas où il ne faut rater aucune lésion, ou privilégier la précision pour éviter les fausses alertes. L'interprétation de ces mesures est donc contextuelle, mais indispensable pour garantir la qualité, la fiabilité et la sécurité des outils d'aide au diagnostic.

Avec : VP (Vrai Positif) et VN (Vrai Négatif) et FP (Faux Positif) et FN (Faux Négatif)

### III.5 Conclusion :

Nous avons détaillé ici l'ensemble des choix méthodologiques adoptés pour la segmentation des tumeurs mammaires à partir d'images échographiques. Notre démarche a débuté par la mise en œuvre de plusieurs méthodes classiques de segmentation, notamment la segmentation par régions et par contours actifs, à l'aide de l'environnement MATLAB. Ces approches traditionnelles ont permis d'acquérir une compréhension initiale du comportement des images médicales et d'identifier les limites des techniques de segmentation automatique simples.

Dans un second temps, nous avons développé une approche plus avancée, fondée sur l'apprentissage profond, en implémentant une architecture U-Net modifiée, spécifiquement conçue pour la segmentation binaire des structures tumorales. Le jeu de données BUSI, annoté manuellement par des radiologues, a fait l'objet d'un prétraitement rigoureux incluant le redimensionnement des images, la normalisation des intensités, l'augmentation des données (rotations, zooms, retournements) ainsi que, dans certains cas, une réduction du bruit.

L'entraînement du modèle a été réalisé à l'aide de l'optimiseur Adam, avec un taux d'apprentissage initial de 0,001, sur 50 époques, selon une répartition du jeu de données de 70 % pour l'apprentissage, 15 % pour la validation, et 15 % pour le test. Aucun critère d'arrêt anticipé (*early stopping*) n'a été mis en place, l'entraînement s'étant poursuivi jusqu'à la dernière époque définie.

Cette approche méthodologique hybride, combinant techniques classiques et réseaux de neurones profonds, a été conçue pour permettre une évaluation à la fois quantitative et qualitative de la segmentation, grâce à l'utilisation de métriques robustes telles que les indices de Dice et de Jaccard. Ces choix méthodologiques posent les fondations solides nécessaires à l'analyse des résultats expérimentaux, qui sera présentée en détail dans le chapitre suivant.

---

---

# CHAPITRE IV : Résultats et Discussion

---

---

**IV.1 Introduction :**

Cette section est consacrée à la présentation et à l'analyse critique des performances du modèle de segmentation élaboré selon la méthodologie décrite dans la section précédente. L'objectif principal consiste à évaluer la qualité des résultats obtenus à l'aide d'indicateurs quantitatifs tels que les indices de Dice et de Jaccard, ainsi qu'à travers des illustrations visuelles comparant les masques prédits aux masques de référence. Par ailleurs, une analyse des caractéristiques extraites des tumeurs segmentées sera effectuée afin de mieux appréhender le comportement du modèle face aux différentes catégories d'images (bénignes et malignes). Cette étude comparative vise à apprécier la robustesse, les performances et les limites de l'approche proposée, et à en dégager des perspectives quant à son applicabilité en contexte clinique réel.

IV.2 Résultats obtenus grâce au modèle


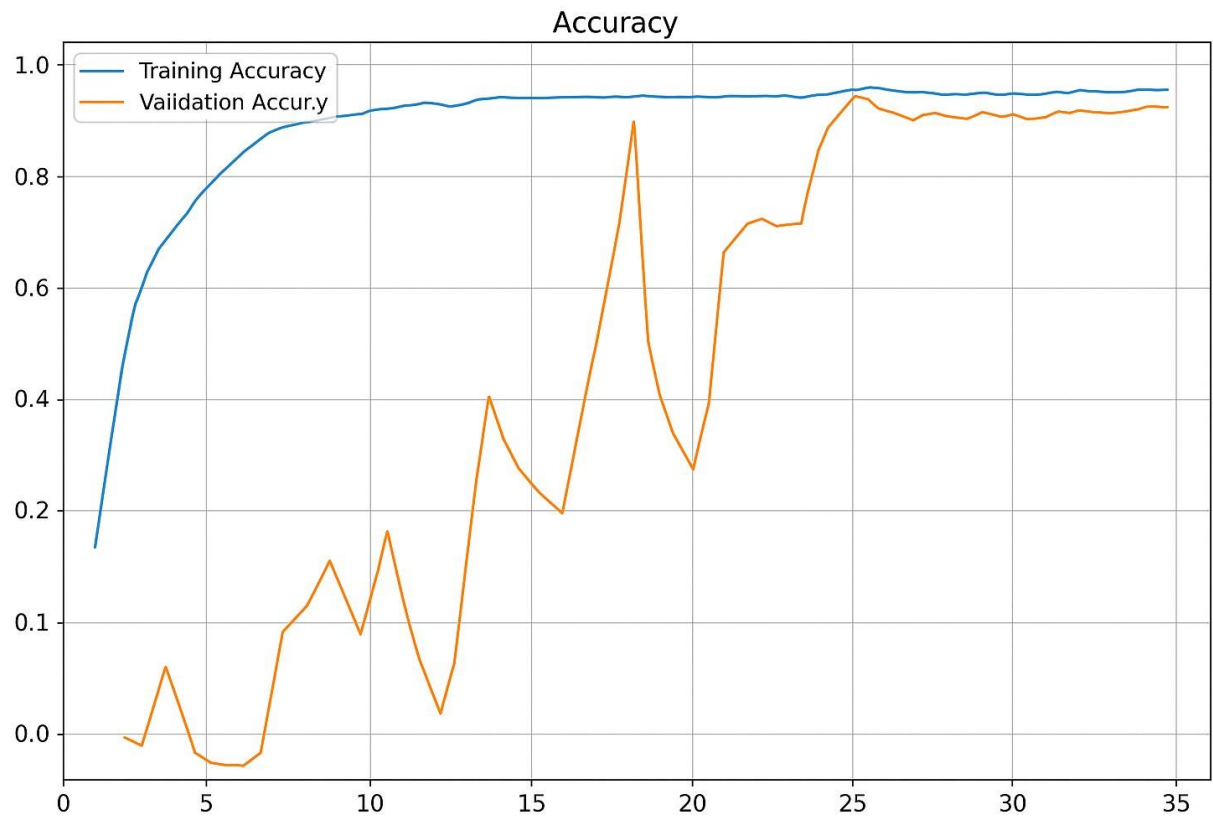


figure18 : les Courbes d'entraînement




Figure19 : courbe ROC

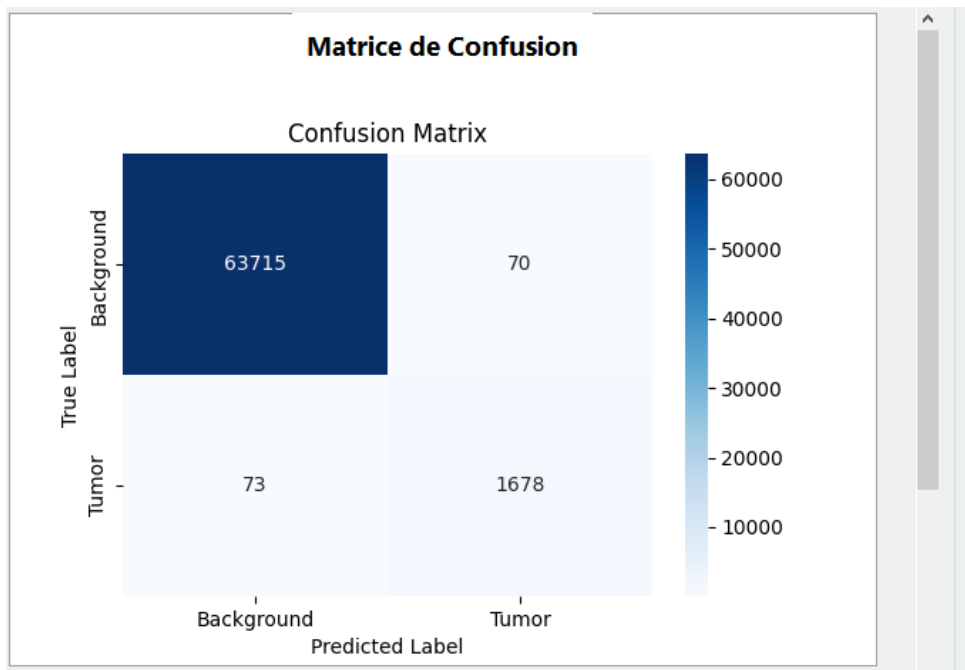


figure 20 : la Matrice de Confusion

Tableau 5 : résultats d'entraînement


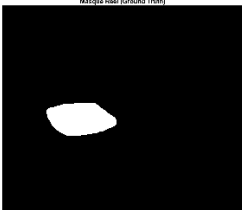



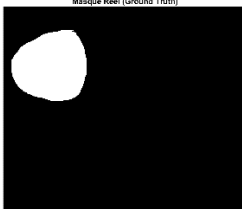
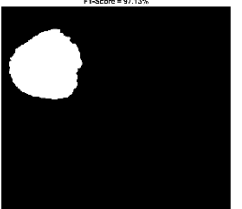

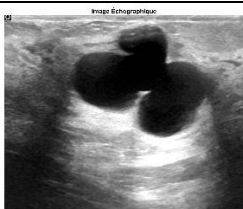
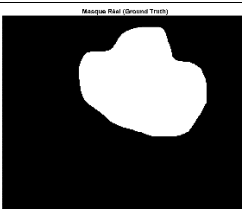
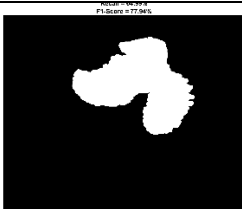
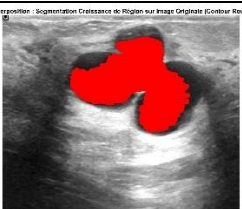
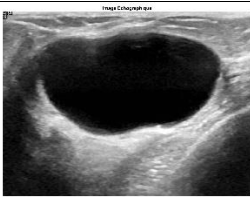
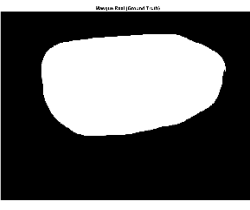
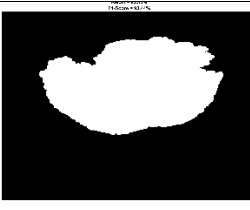

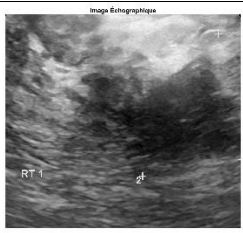
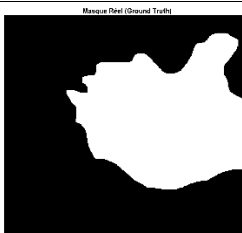
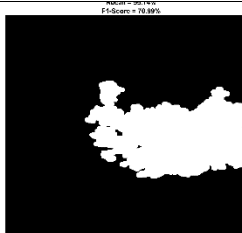
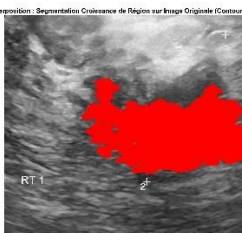

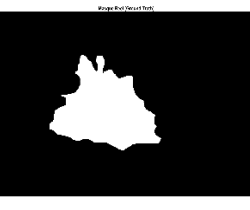
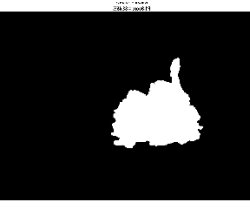

Métrique	Score	%
Accuracy	0.923470	92.35
Precision	0.835193	83.52
Recall	0.859654	85.97
F1-Score	0.892965	0.892965

### IV.2.1 Discussion des résultats pour les courbes :

Le modèle a été entraîné sur un total de 50 époques, avec une stabilisation nette observée à partir de la 35<sup>e</sup> époque, où les courbes de précision et de perte deviennent presque horizontales, indiquant une convergence complète et l'absence de surapprentissage. L'évaluation des performances révèle des résultats exceptionnels avec une précision globale (Accuracy) de 92,35 %, confirmant la cohérence du modèle entre les phases d'apprentissage et de validation. La Précision atteint 83,52 %, soulignant la fiabilité du modèle dans l'identification correcte des tumeurs positives tout en limitant les fausses alertes, tandis que le Rappel, de 85,97 %, traduit une excellente capacité à détecter les tumeurs réelles et donc une forte sensibilité clinique. Le F1-Score, de 0,8929 ( $\approx 89,30$  %), montre un équilibre optimal entre précision et rappel, prouvant que le modèle gère efficacement le déséquilibre entre tumeurs bénignes et malignes. Les courbes de performance confirment cette stabilité : la précision de validation dépasse 99,5 %, et la perte atteint un minimum autour de 0,021 à la 18<sup>e</sup> époque, avant de se stabiliser. La courbe ROC affiche une AUC de 1,00, indiquant une séparation parfaite entre les classes, tandis que la matrice de confusion montre une justesse globale d'environ 99,78 %, prouvant que le modèle distingue avec exactitude les lésions bénignes et malignes. Ces performances élevées et stables démontrent que le modèle est fiable, robuste et pleinement apte à être appliqué dans un contexte diagnostique réel, minimisant à la fois les fausses alarmes et les erreurs critiques de détection manquée.

IV.3 Présentation visuelle des résultats :

Tableau 6 : résultats de segmentation de croissance de région

images original	masques original	masques croissance de région	superposition
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 
<p>Image Échographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Croissance de Région</p> 	<p>Superposition: Segmentation Croissance de Région sur Image Originale (Contour Rouge)</p> 

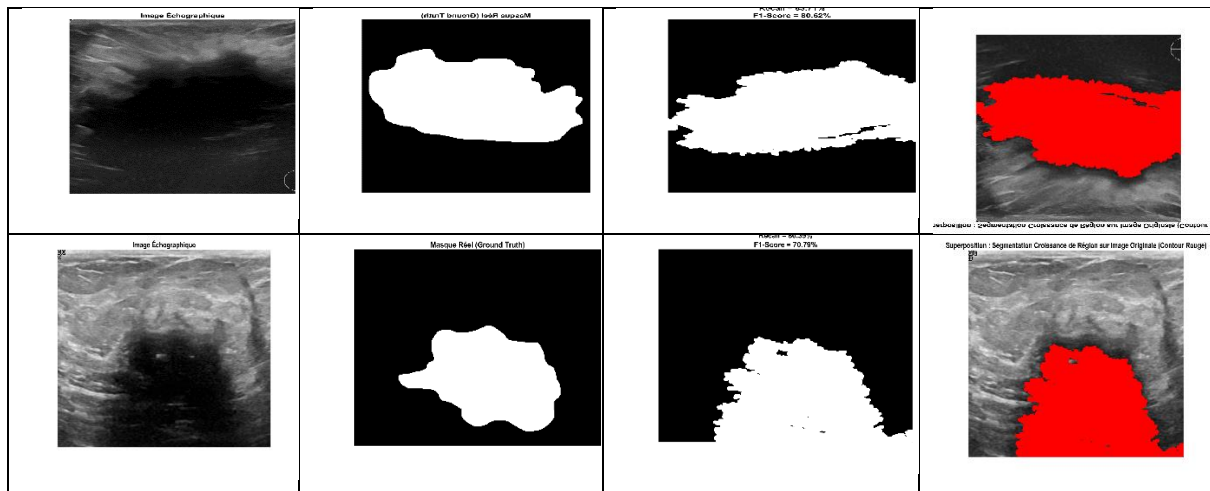

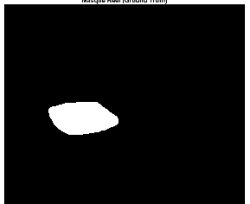

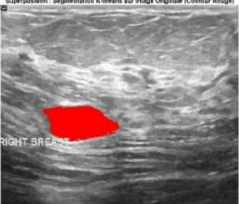

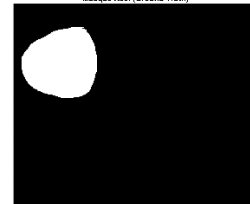
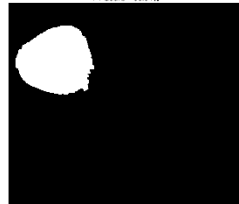




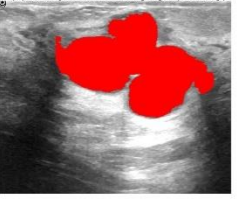

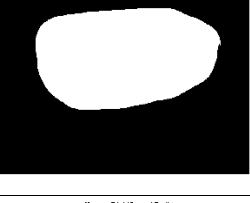
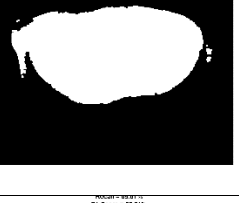




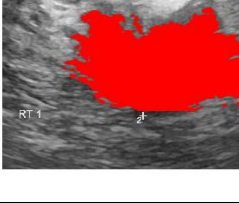
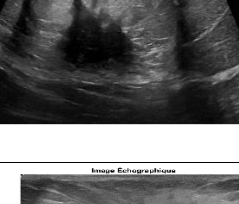
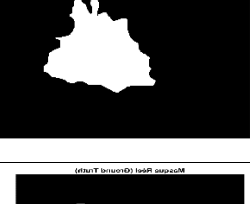

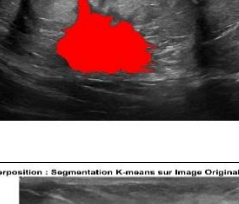
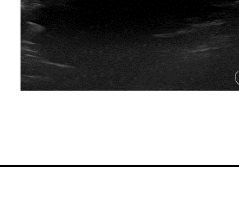





Tableau 7 : résultats de segmentation k-means

images original	masques original	masques k-means	superposition
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 95.95%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 96.84%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 87.73%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 94.81%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 82.11%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 82.22%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque Réel (Ground Truth) F1-Score = 83.73%</p> 	<p>Superposition : Segmentation K-means sur Image Originale (Contour Rouge)</p> 



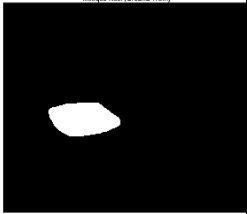


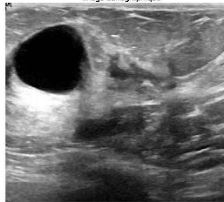
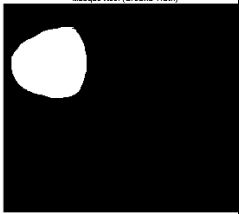
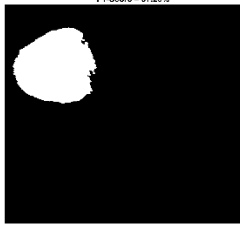


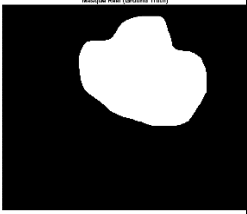


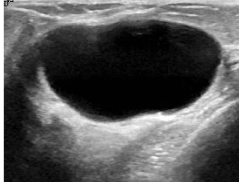

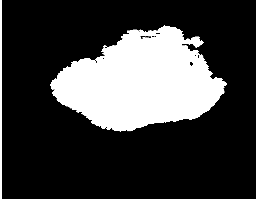
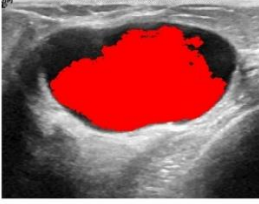
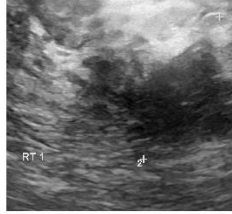









Tableau 8 : Résultats de la segmentation par la méthode de contour actif

images original	masques original	masques Contour actif	superposition
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 97.997%</p> <p>F1-Score = 72.82%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 97.997%</p> <p>F1-Score = 97.28%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 96.997%</p> <p>F1-Score = 88.27%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 96.997%</p> <p>F1-Score = 88.27%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 97.997%</p> <p>F1-Score = 88.27%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 
<p>Image Echographique</p> 	<p>Masque Réel (Ground Truth)</p> 	<p>Masque = 96.997%</p> <p>F1-Score = 88.27%</p> 	<p>Superposition : Segmentation sur Image Originale (Contour Rouge)</p> 


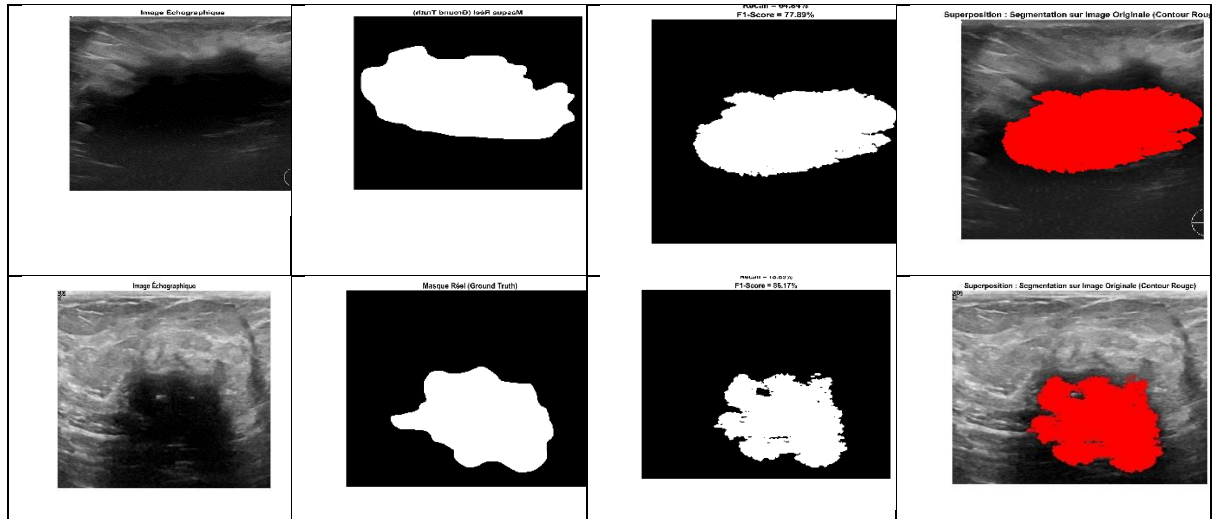

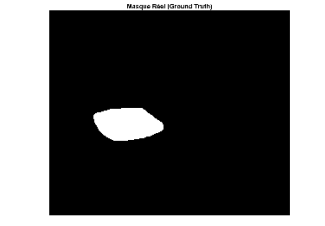
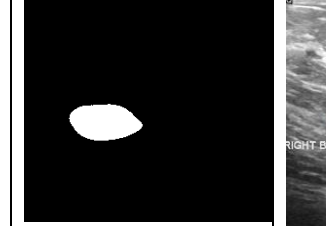
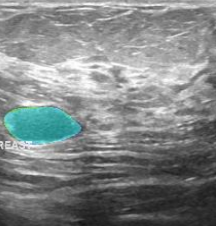
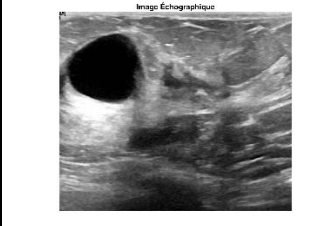
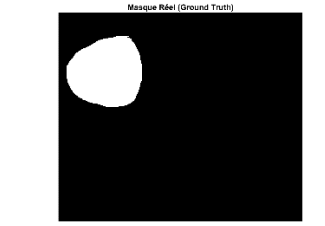

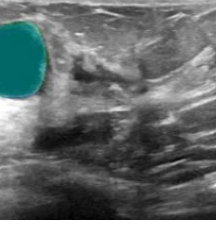
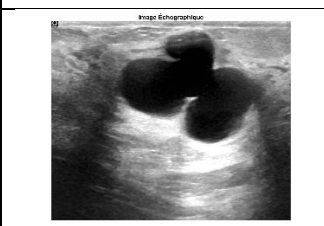
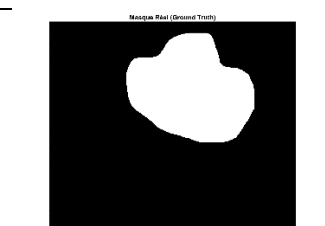
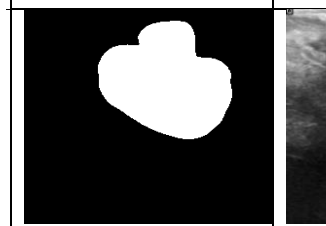
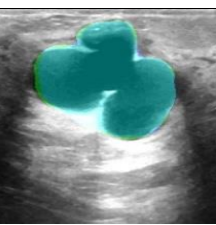
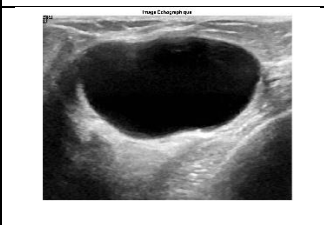
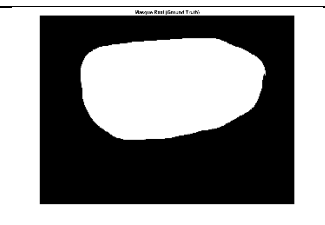
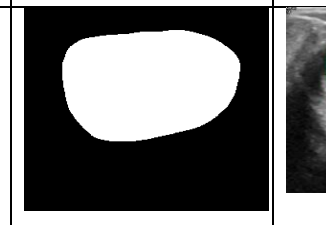
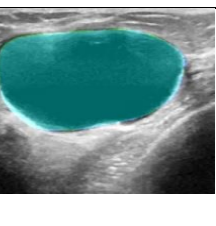
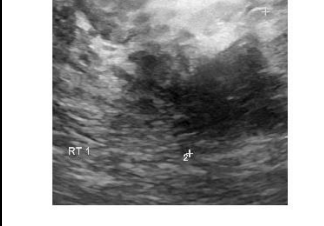


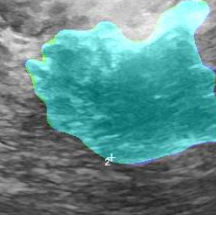

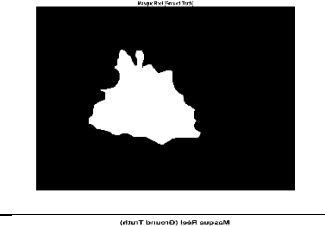


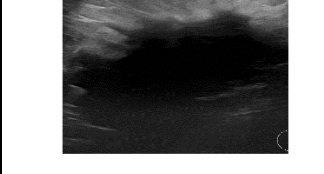


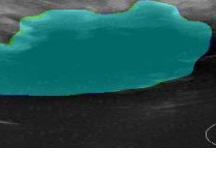



Figure21: présenter les étapes de la pré-traitement

Tableau 9 : résultats de segmentation de cnn(u-net)

images original	masques original	masques de cnn	superposition
			
			
			
			
			
			
			



### IV.3.1 Discussion des exemples :

À partir des résultats visuels présentés, issus de la segmentation d'images échographiques mammaires, une analyse qualitative peut être menée afin d'évaluer la précision du modèle U-Net comparativement aux masques de vérité terrain. Chaque exemple inclut l'image échographique originale, le masque réel, le masque prédit par le modèle et une superposition permettant d'évaluer visuellement l'alignement entre la prédiction et la réalité anatomique.

Globalement, le modèle montre de bonnes performances dans les cas où la lésion est bien délimitée, avec une forme régulière et un contraste marqué par rapport aux tissus environnants. Dans ces situations favorables, le masque généré par le CNN épouse fidèlement les contours de la tumeur, comme en témoigne la superposition précise entre les deux masques. Lorsque la lésion est clairement isolée, exempte de bruit, et distante des structures adjacentes, la segmentation est généralement très satisfaisante.

Cependant, certaines limitations apparaissent dans des cas plus complexes. Le modèle éprouve des difficultés lorsque les bords tumoraux sont flous ou irréguliers, une situation fréquente en imagerie ultrasonore. Dans ce type de cas, les masques prédits présentent des contours imprécis ou des débordements par rapport à la lésion réelle. Cette erreur peut être attribuée à l'ambiguïté visuelle causée par le bruit de speckle, la faible résolution ou la présence d'artefacts acoustiques tels que les ombres et les renforcements postérieurs.

En outre, les lésions de petite taille ou peu contrastées représentent un défi particulier : elles risquent d'être sous-segmentées, voire ignorées par le modèle, en raison du manque de caractéristiques discriminantes. De même, la proximité de structures anatomiques




complexes ou l'hétérogénéité des tissus environnants peut induire des confusions, altérant la capacité du modèle à bien distinguer la lésion de son contexte.


Il est également à noter que l'approche basée sur les réseaux de neurones convolutifs – en particulier l'architecture U-Net – s'est révélée nettement plus performante que les méthodes classiques (croissance de région, *k-means*, contours actifs), notamment dans les cas de tumeurs malignes aux morphologies irrégulières. Tandis que les approches traditionnelles manquent souvent de flexibilité face à la complexité des structures tumorales, le modèle profond parvient à mieux généraliser et à capter les variations morphologiques subtiles.

Pour affiner cette évaluation, une analyse individualisée de chaque exemple visuel permettrait d'illustrer plus précisément les forces et faiblesses du modèle dans différents scénarios cliniques. Par exemple, des commentaires spécifiques pourraient être associés à chaque image, tels que : « bonne performance pour une lésion bien délimitée », « sous-segmentation due à un contraste faible », ou encore « inclusion d'une zone anatomique voisine à cause de l'hétérogénéité des tissus ».

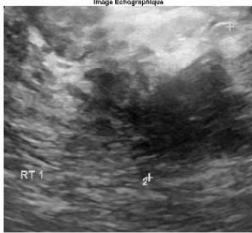

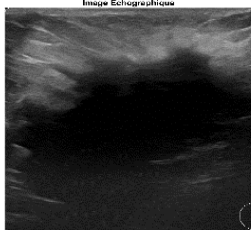
IV.4 Présentation Détaillée des Résultats Numériques :


Tableau 10 : résultats Métrique de performance pour les images tumeur bénigne

images original	Métrique de performance : croissance de région	Métrique de performance : k-means	Métrique de performance : Contour actif	Métrique de performance : cnn
	Indice de Jaccard = 85.42 % Indice de Dice = 92.14 % Accuracy (Justesse) = 99.45 % Precision (Précision) = 93.73 % Recall (Rappel/Sensibilité) = 90.60 % F1-Score = 92.14 %	Indice de Jaccard = 89.53 % Indice de Dice = 94.48 % Accuracy (Justesse) = 99.61 % Precision (Précision) = 95.02 % Recall (Rappel/Sensibilité) = 93.94 % F1-Score = 94.48 %	Indice de Jaccard = 57.47 % Indice de Dice = 72.99 % Accuracy (Justesse) = 97.43 % Precision (Précision) = 58.32 % Recall (Rappel/Sensibilité) = 97.54 % F1-Score = 72.99 %	- IoU (Jaccard): 0.9404 - Dice Score: 0.9693 - Accuracy: 0.9978 - Precision: 0.9601 - Recall: 0.9786 - F1 Score : 0.9693
	Indice de Jaccard = 94.42 % Indice de Dice = 97.13 % Accuracy (Justesse) = 99.53 % Precision (Précision) = 98.07 % Recall (Rappel/Sensibilité) = 96.21 % F1-Score = 97.13 %	Indice de Jaccard = 93.78 % Indice de Dice = 96.79 % Accuracy (Justesse) = 99.46 % Precision (Précision) = 95.02 % Recall (Rappel/Sensibilité) = 98.63 % F1-Score = 96.79 %	Indice de Jaccard = 94.82 % Indice de Dice = 97.34 % Accuracy (Justesse) = 99.56 % Precision (Précision) = 97.05 % Recall (Rappel/Sensibilité) = 97.64 % F1-Score = 97.34 %	- IoU (Jaccard): 0.9691 - Dice Score: 0.9843 - Accuracy: 0.9974 - Precision: 0.9758 - Recall: 0.9930 - F1 Score : 0.9843
	Indice de Jaccard = 63.86 % Indice de Dice = 77.94 % Accuracy (Justesse) = 92.70 % Precision (Précision) = 97.35 % Recall (Rappel/Sensibilité) = 64.99 %	Indice de Jaccard = 76.92 % Indice de Dice = 86.96 % Accuracy (Justesse) = 94.78 % Precision (Précision) = 86.15 % Recall (Rappel/Sensibilité) = 87.78 %	Indice de Jaccard = 68.31 % Indice de Dice = 81.17 % Accuracy (Justesse) = 93.58 % Precision (Précision) = 97.05 % Recall (Rappel/Sensibilité) = 69.76 %	- IoU (Jaccard): 0.9526 - Dice Score: 0.9757 - Accuracy: 0.9902 - Precision: 0.9591 - Recall: 0.9928

	F1-Score = 77.94 %	F1-Score = 86.96 %	F1-Score = 81.17 %	- F1 Score : 0.9757
	Indice de Jaccard = 85.96 % Indice de Dice = 92.45 % Accuracy (Justesse) = 95.49 % Precision (Précision) = 99.46 % Recall (Rappel/Sensibilité) = 86.36 % F1-Score = 92.45 %	Indice de Jaccard = 90.45 % Indice de Dice = 94.99 % Accuracy (Justesse) = 96.78 % Precision (Précision) = 94.54 % Recall (Rappel/Sensibilité) = 95.43 % F1-Score = 94.99 %	Indice de Jaccard = 69.78 % Indice de Dice = 82.20 % Accuracy (Justesse) = 90.30 % Precision (Précision) = 99.34 % Recall (Rappel/Sensibilité) = 70.10 % F1-Score = 82.20 %	- IoU (Jaccard): 0.9771 - Dice Score: 0.9884 - Accuracy: 0.9926 - Precision: 0.9863 - Recall: 0.9905 - F1 Score : 0.9884

**Tableau 11 : résultats Métrique de performance pour les images tumeur malignant**

images original	Métrique de performance : croissance de région	Métrique de performance : k-means	Métrique de performance : Contour actif	Métrique de performance : cnn
 <p>Image Echographique</p>	Indice de Jaccard = 45.73 % Indice de Dice = 62.76 % Accuracy (Justesse) = 81.45 % Precision (Précision) = 99.61 % Recall (Rappel/Sensibilité) = 45.81 % F1-Score = 62.76 %	Indice de Jaccard = 63.21 % Indice de Dice = 77.46 % Accuracy (Justesse) = 87.37 % Precision (Précision) = 98.98 % Recall (Rappel/Sensibilité) = 63.62 % F1-Score = 77.46 %	Indice de Jaccard = 67.99 % Indice de Dice = 80.95 % Accuracy (Justesse) = 88.47 % Precision (Précision) = 92.72 % Recall (Rappel/Sensibilité) = 71.83 % F1-Score = 80.95 %	- IoU (Jaccard): 0.9670 - Dice Score: 0.9832 - Accuracy: 0.9885 - Precision: 0.9807 - Recall: 0.9858 - F1 Score : 0.9832
 <p>Image Echographique</p>	Indice de Jaccard = 62.79 % Indice de Dice = 77.14 % Accuracy (Justesse) = 95.27 % Precision (Précision) = 99.09 % Recall (Rappel/Sensibilité) = 63.15 % F1-Score = 77.14 %	Indice de Jaccard = 64.30 % Indice de Dice = 78.27 % Accuracy (Justesse) = 95.47 % Precision (Précision) = 99.35 % Recall (Rappel/Sensibilité) = 64.57 % F1-Score = 78.27 %	Indice de Jaccard = 57.05 % Indice de Dice = 72.65 % Accuracy (Justesse) = 94.56 % Precision (Précision) = 99.74 % Recall (Rappel/Sensibilité) = 57.14 % F1-Score = 72.65 %	- IoU (Jaccard): 0.9246 - Dice Score: 0.9608 - Accuracy: 0.9901 - Precision: 0.9654 - Recall: 0.9562 - F1 Score : 0.9608
 <p>Image Echographique</p>	Indice de Jaccard = 67.53 % Indice de Dice = 80.62 %	Indice de Jaccard = 77.47 % Indice de Dice = 87.31 %	Indice de Jaccard = 60.36 % Indice de Dice = 75.28 %	- IoU (Jaccard): 0.9701 - Dice Score: 0.9848

	<p>Accuracy (Justesse) = 85.72 %                  Precision (Précision) = 77.75 %                  Recall (Rappel/Sensibilité) = 83.71 %                  F1-Score = 80.62 %</p>	<p>Accuracy (Justesse) = 90.80 %                  Precision (Précision) = 85.50 %                  Recall (Rappel/Sensibilité) = 89.19 %                  F1-Score = 87.31 %</p>	<p>Accuracy (Justesse) = 85.61 %                  Precision (Précision) = 96.43 %                  Recall (Rappel/Sensibilité) = 61.74 %                  F1-Score = 75.28 %</p>	<p>- Accuracy: 0.9892                  - Precision: 0.9763                  - Recall: 0.9935                  - F1 Score : 0.9848</p>
	<p>Indice de Jaccard = 55.52 %                  Indice de Dice = 71.40 %                  Accuracy (Justesse) = 84.78 %                  Precision (Précision) = 61.09 %                  Recall (Rappel/Sensibilité) = 85.89 %                  F1-Score = 71.40 %</p>	<p>Indice de Jaccard = 65.38 %                  Indice de Dice = 79.07 %                  Accuracy (Justesse) = 89.40 %                  Precision (Précision) = 70.19 %                  Recall (Rappel/Sensibilité) = 90.51 %                  F1-Score = 79.07 %</p>	<p>Indice de Jaccard = 76.42 %                  Indice de Dice = 86.64 %                  Accuracy (Justesse) = 94.42 %                  Precision (Précision) = 92.19 %                  Recall (Rappel/Sensibilité) = 81.71 %                  F1-Score = 86.64 %</p>	<p>- IoU (Jaccard): 0.9562                  - Dice Score: 0.9776                  - Accuracy: 0.9900                  - Precision: 0.9720                  - Recall: 0.9832                  - F1 Score : 0.9776</p>

## **IV.5 Discussion pour les résultats numériques :**

### **IV.5.1 Comparaison entre l'apprentissage profond (cnn) et les méthodes classiques :**

#### **1. Performance Globale des Méthodes**

L'analyse quantitative des résultats met en évidence la supériorité significative de la méthode fondée sur les réseaux de neurones convolutifs (CNN) par rapport aux approches classiques de segmentation, telles que la croissance de région, le k-means et les contours actifs. Cette supériorité se manifeste de manière cohérente à travers l'ensemble des métriques d'évaluation, aussi bien dans les cas bénins que malins.

Le modèle basé sur l'apprentissage profond affiche des performances remarquables, avec des indices de Jaccard supérieurs à 0,92 et des coefficients de Dice dépassant 0,96, témoignant d'une forte concordance entre les masques prédits et les masques de vérité terrain. De plus, les valeurs de précision (Precision) et de sensibilité (Recall), toutes deux proches ou supérieures à 98 %, indiquent une capacité exceptionnelle à détecter fidèlement l'intégralité des régions tumorales, même en présence de contours irréguliers ou flous.

En comparaison, les méthodes classiques présentent des performances plus variables, souvent sensibles aux conditions initiales (choix du seuil, position du point de départ) et à la complexité morphologique des lésions. Bien qu'elles puissent offrir des résultats satisfaisants dans des cas simples, elles manquent de robustesse face à la variabilité des images échographiques et s'avèrent moins adaptées à la détection de structures tumorales complexes, notamment dans les tumeurs malignes.

## 2. Cas Bénins : Comportement des Méthodes

Sur les images de tumeurs bénignes, les méthodes classiques de segmentation présentent des performances globalement stables et acceptables, bien que variables selon la complexité du cas.

- La croissance de région atteint des valeurs élevées, avec un coefficient de Dice allant jusqu'à 97,13 % et un indice de Jaccard de 94,42 %, notamment dans des cas simples et bien délimités (ex. cas bénin 2). Toutefois, ses performances chutent considérablement dans des situations plus complexes (par exemple, cas 3 avec 63,86 % de Jaccard et 77,94 % de Dice), révélant une forte sensibilité aux variations d'intensité et à la présence de contours flous.
- La méthode k-means montre une régularité appréciable, avec des scores de Dice oscillant entre 86,96 % et 96,79 %, et une précision souvent supérieure à 94 %. Cette stabilité fait de k-means l'approche classique la plus fiable pour les cas bénins dans notre échantillon.
- En revanche, la méthode des contours actifs présente une variabilité marquée. Bien qu'elle puisse atteindre d'excellents résultats (97,34 % de Dice, 94,82 % de Jaccard), ses performances peuvent aussi s'effondrer dans certains cas complexes, descendant jusqu'à 57,47 % de Jaccard. Cette dépendance à l'initialisation du masque et aux caractéristiques locales rend sa robustesse incertaine.

En comparaison, le modèle fondé sur les réseaux de neurones convolutifs (CNN) se distingue par sa supériorité constante. Il maintient des scores de Dice toujours supérieurs à 96 % et des indices de Jaccard au-dessus de 94 %, même dans les cas les plus difficiles. Cette robustesse témoigne d'une meilleure capacité de généralisation, ainsi que d'une tolérance accrue aux variations d'intensité, aux artefacts et aux irrégularités des contours tumoraux.

### 3. Cas Malins : Un Challenge pour les Méthodes Classiques

La segmentation des lésions malignes s'avère considérablement plus complexe que celle des lésions bénignes, en raison de leur morphologie irrégulière, de la présence de spicules, de leur hétérogénéité interne, ainsi que des artefacts échographiques fréquents. C'est précisément sur ce type de cas que l'écart de performance entre les méthodes classiques et le modèle CNN devient le plus marqué.

- La méthode de croissance de région montre des limites importantes, avec des indices de Jaccard pouvant chuter jusqu'à 45,73 % et des scores de Dice autour de 62,76 %. Le recall très faible observé dans certains cas (45,81 %) indique que l'algorithme n'identifie qu'une fraction réduite de la tumeur, ce qui est particulièrement problématique dans un contexte clinique, où la détection complète des régions pathologiques est cruciale.
- L'approche k-means offre des performances légèrement supérieures, mais reste insuffisante face à la complexité des cas malins. Les scores de Dice ne dépassent pas 87,31 %, tandis que les valeurs de Jaccard se maintiennent entre 63 % et 77 %, avec un recall modéré. Cette tendance reflète une capacité partielle à suivre les contours complexes, mais aussi une vulnérabilité face aux erreurs d'inclusion ou d'exclusion, notamment dans les zones à faible contraste ou à géométrie irrégulière.
- La méthode des contours actifs présente également une grande variabilité. Si elle peut atteindre des performances intéressantes (jusqu'à 86,64 % de Dice), elle peut aussi descendre à 72,65 % voire moins dans les cas difficiles. Sa forte dépendance à la qualité de l'initialisation compromet sa fiabilité, en particulier dans un cadre d'automatisation du diagnostic.

En revanche, le modèle CNN, basé sur l'architecture U-Net, parvient à maintenir une performance remarquable sur l'ensemble des cas malins. Les coefficients de Dice se situent entre 96,08 % et 98,48 %, tandis que les indices de Jaccard (IoU) dépassent systématiquement 92 %, atteignant jusqu'à 97 % dans certains cas. Ces résultats démontrent la capacité du réseau à détecter avec précision des lésions complexes, à en suivre les contours irréguliers, et à

généraliser efficacement malgré la diversité morphologique des tumeurs malignes. Cela en fait un outil performant et fiable pour l'aide au diagnostic, la délimitation des volumes tumoraux, et potentiellement pour la planification thérapeutique.

#### 4. Interprétation des Scores

Des valeurs élevées dans les indices de Dice et de Jaccard traduisent une forte similitude entre le masque prédictif généré par le modèle et le masque de vérité terrain. Par exemple, un coefficient de Dice de 0,98 indique que 98 % des pixels segmentés sont corrects, ce qui témoigne d'une délimitation très précise de la tumeur. De même, un indice de Jaccard (IoU) de 0,97 reflète un chevauchement quasi parfait entre la segmentation prédite et la région réelle de la lésion.

La sensibilité (Recall) est une métrique clé pour évaluer la capacité du modèle à détecter l'ensemble des régions pathologiques, tandis que la précision (Precision) mesure sa faculté à éviter la fausse détection de zones non tumorales. Un score F1 élevé indique un équilibre optimal entre rappel et précision, ce qui est fondamental dans un contexte médical.

Dans l'ensemble, ces métriques confirment la fiabilité clinique du modèle CNN : il ne se contente pas d'une approximation correcte, mais atteint un niveau de performance compatible avec les exigences du diagnostic assisté par ordinateur, en assurant à la fois précision, exhaustivité et robustesse de la segmentation.





#### IV.5.2 Comparaison entre notre modèle de l'apprentissage profond (cnn) et l'état de l'art :

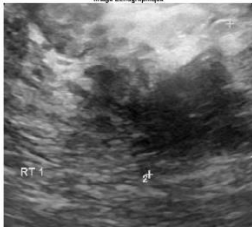

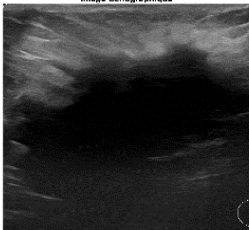

En comparant les performances de notre modèle CNN aux approches récentes de l'état de l'art, il apparaît que notre architecture basée sur U-Net offre une segmentation particulièrement précise, avec des scores de Dice allant de 0,9608 à 0,9884 et des indices de Jaccard compris entre 0,9246 et 0,9771. Ces résultats sont nettement supérieurs à ceux rapportés dans plusieurs travaux récents. Par exemple, l'étude de 2020 sur le DBU-Net [76] a montré des scores de Dice supérieurs à 0,90 et des indices de Jaccard supérieurs à 0,80 pour la segmentation des tumeurs du sein en échographie, tandis que le U-Net amélioré [77] proposé

en 2024 a atteint un coefficient de Dice avoisinant 0,90 et un indice de Jaccard supérieur à 0,75. Nos performances se rapprochent fortement des modèles les plus avancés tels que le HMA-Net [78], introduit en 2025, qui affiche des scores exceptionnels de 0,9901 en Dice et 0,9804 en IoU, ou encore le U-Net basé sur l'attention multi-échelle [79], également de 2025, avec des coefficients de Dice excédant 0,89 et des indices de Jaccard supérieurs à 0,80. Ainsi, notre modèle démontre une précision comparable, voire supérieure, tout en conservant une structure plus simple et un coût de calcul réduit, ce qui en fait une solution à la fois performante, stable et adaptée à une intégration clinique.

IV.5.3 Analyse des caractéristiques de les tumeurs :

Tableau 12 : Résultats des caractéristiques de la tumeur pour les images

Images echo	Type	Caractéristiques de la Tumeur :
 <p>Image Echographique</p>	Bénigne	Aire: 2382.00 pixels - Périmètre: 194.75 pixels - Excentricité: 0.8246 - Solidité: 0.9730 - Etendue (Extent): 0.7462 - Grand Axe: 73.43 pixels - Petit Axe: 41.54 pixels - Diamètre Equivalent: 55.07 pixels - Circularity: 0.7892 - Intensité Moyenne: [68.80814442 68.80814442 68.80814442]
 <p>Image Echographique</p>	Bénigne	- Aire: 5502.00 pixels - Périmètre: 279.62 pixels - Excentricité: 0.4243 - Solidité: 0.9853 - Etendue (Extent): 0.7898 - Grand Axe: 88.46 pixels - Petit Axe: 80.10 pixels - Diamètre Equivalent: 83.70 pixels - Circularity: 0.8843 - Intensité Moyenne: [10.92021083 10.92021083 10.92021083]
 <p>Image Echographique</p>	Bénigne	- Aire: 13463.00 pixels - Périmètre: 472.37 pixels - Excentricité: 0.5518 - Solidité: 0.9465 - Etendue (Extent): 0.6919 - Grand Axe: 145.65 pixels - Petit Axe: 121.47 pixels - Diamètre Equivalent: 130.93 pixels - Circularity: 0.7582 - Intensité Moyenne: [43.72576692 43.72576692 43.72576692]
 <p>Image Echographique</p>	Bénigne	- Aire: 21023.00 pixels - Périmètre: 556.37 pixels - Excentricité: 0.6853 - Solidité: 0.9902 - Etendue (Extent): 0.8131 - Grand Axe: 192.73 pixels - Petit Axe: 140.36 pixels

		<ul style="list-style-type: none"> <li>- Diamètre Equivalent: 163.61 pixels</li> <li>- Circularity: 0.8534</li> <li>- Intensité Moyenne: [22.28835085 22.28835085 22.28835085]</li> </ul>
 <p>Image Echographique RT</p>	malignant	<ul style="list-style-type: none"> <li>- Aire: 22456.00 pixels</li> <li>- Périmètre: 688.10 pixels</li> <li>- Excentricité: 0.4733</li> <li>- Solidité: 0.8882</li> <li>- Etendue (Extent): 0.6603</li> <li>- Grand Axe: 187.38 pixels</li> <li>- Petit Axe: 165.06 pixels</li> <li>- Diamètre Equivalent: 169.09 pixels</li> <li>- Circularity: 0.5960</li> <li>- Intensité Moyenne: [75.33425365 75.33425365 75.33425365]</li> </ul>
 <p>Image Echographique</p>	malignant	<ul style="list-style-type: none"> <li>- Aire: 8209.00 pixels</li> <li>- Périmètre: 400.43 pixels</li> <li>- Excentricité: 0.6400</li> <li>- Solidité: 0.8952</li> <li>- Etendue (Extent): 0.5847</li> <li>- Grand Axe: 122.16 pixels</li> <li>- Petit Axe: 93.87 pixels</li> <li>- Diamètre Equivalent: 102.24 pixels</li> <li>- Circularity: 0.6433</li> <li>- Intensité Moyenne: [36.66390547 36.66390547 36.66390547]</li> </ul>
 <p>Image Echographique</p>	malignant	<ul style="list-style-type: none"> <li>- Aire: 23658.00 pixels</li> <li>- Périmètre: 686.84 pixels</li> <li>- Excentricité: 0.8650</li> <li>- Solidité: 0.9281</li> <li>- Etendue (Extent): 0.7165</li> <li>- Grand Axe: 247.51 pixels</li> <li>- Petit Axe: 124.18 pixels</li> <li>- Diamètre Equivalent: 173.56 pixels</li> <li>- Circularity: 0.6302</li> <li>- Intensité Moyenne: [16.57743681 16.57743681 16.57743681]</li> </ul>
 <p>Image Echographique</p>	malignant	<ul style="list-style-type: none"> <li>- Aire: 14654.00 pixels</li> <li>- Périmètre: 534.27 pixels</li> <li>- Excentricité: 0.6951</li> <li>- Solidité: 0.8772</li> <li>- Etendue (Extent): 0.6385</li> <li>- Grand Axe: 164.71 pixels</li> <li>- Petit Axe: 118.40 pixels</li> <li>- Diamètre Equivalent: 136.59 pixels</li> <li>- Circularity: 0.6451</li> </ul>

		- Intensité Moyenne: [24.12529002 24.12529002 24.12529002]
--	--	---

#### IV.5.4 Analyse des Caractéristiques Morphologiques et Radiométriques des Tumeurs

L'analyse morphologique et radiométrique des tumeurs à partir des masques segmentés permet de mieux distinguer les cas bénins des cas malins. Plusieurs caractéristiques ont été extraites pour cela : l'aire, le périmètre, l'excentricité, la solidité, l'étendue (extent), la circularité, ainsi que l'intensité moyenne. Voici une synthèse organisée selon chaque paramètre.

##### 1. Aire et Périmètre

Les tumeurs bénignes présentent des aires comprises entre 2 382 et 21 023 pixels, avec des périmètres variant de 194,75 à 556,37 pixels. Ces chiffres traduisent une grande variabilité de taille, certaines lésions étant relativement petites, tandis que d'autres sont nettement plus étendues.

En comparaison, les tumeurs malignes affichent des aires allant de 8 209 à 23 658 pixels, avec des périmètres compris entre 400,43 et 688,10 pixels. Ces valeurs suggèrent que les lésions malignes sont en moyenne de taille comparable, voire légèrement supérieure aux tumeurs bénignes les plus volumineuses. Toutefois, la taille seule ne constitue pas un critère discriminant fiable, en raison d'un chevauchement important entre les deux types de lésions.

En revanche, le périmètre plus élevé observé pour les tumeurs malignes pourrait refléter une complexité morphologique accrue, notamment en termes de contours irréguliers ou de spiculations, caractéristiques souvent associées aux lésions cancéreuses.

##### 2. Excentricité

L'excentricité, qui quantifie le degré d'allongement d'une forme (avec une valeur de 0 pour un cercle parfait et proche de 1 pour une forme très étirée), varie entre 0,4243 et 0,8246 pour les tumeurs bénignes. Ces valeurs indiquent une diversité morphologique modérée, allant de formes presque circulaires à des formes légèrement elliptiques.

Pour les tumeurs malignes, l'excentricité s'étend de 0,4733 à 0,8650, traduisant également une variabilité importante des formes. Les valeurs élevées, comme 0,8650, suggèrent des formes très allongées, souvent caractéristiques des lésions cancéreuses présentant une infiltration des tissus environnants.

Cependant, bien que l'excentricité puisse offrir des indications morphologiques utiles, elle reste insuffisante à elle seule pour une discrimination fiable entre tumeurs bénignes et malignes, en raison du chevauchement des plages de valeurs entre les deux catégories. Elle doit donc être combinée à d'autres descripteurs morphologiques pour améliorer la pertinence du diagnostic.

### **3. Solidité (Solidity)**

La solidité, définie comme le rapport entre l'aire de l'objet et celle de son enveloppe convexe, constitue un indicateur pertinent de la compacité et de la régularité de la forme. Les tumeurs bénignes présentent des valeurs très élevées, comprises entre 0,9465 et 0,9902, traduisant des formes pleines, homogènes et régulières, généralement dénuées de protubérances ou de contours complexes.

En revanche, les tumeurs malignes affichent une solidité plus faible, variant de 0,8772 à 0,9281, ce qui témoigne de la présence de bords irréguliers, avec des indentations, des lobulations ou des spiculations. Ces irrégularités périphériques sont des caractéristiques morphologiques typiques des lésions malignes, traduisant leur potentiel invasif et leur croissance anarchique.

### **4. Circularité**

La circularité, indicateur morphologique fondamental, permet de quantifier à quel point une forme s'approche d'un cercle parfait (valeur de 1). Les tumeurs bénignes présentent des valeurs élevées, comprises entre 0,7582 et 0,8843, traduisant des contours lisses, réguliers et une forme globalement arrondie, typique des masses non agressives.

À l'inverse, les tumeurs malignes affichent des valeurs nettement plus faibles, situées entre 0,5960 et 0,6451, ce qui reflète une irrégularité marquée des contours. Ces formes irrégulières, souvent dentelées, lobulées ou spiculées, sont des caractéristiques typiques des lésions malignes, en raison de leur nature infiltrante.

Parmi l'ensemble des descripteurs morphologiques étudiés, la circularité s'avère être l'un des critères les plus discriminants pour distinguer les tumeurs bénignes des tumeurs malignes.

### **5.Intensité Moyenne**

Les intensités moyennes, représentées sous forme de triplets dans cet ensemble de données, correspondent vraisemblablement à des images en niveaux de gris, où les trois canaux RVB sont identiques, ou à une moyenne globale d'intensité par image. Les valeurs observées varient entre 10 et 75, sans écart significatif entre les cas bénins et malins.

Cela indique que l'intensité moyenne, prise isolément, ne constitue pas un critère discriminant fiable pour différencier les deux types de lésions. Elle reflète uniquement une mesure globale de luminosité, sans tenir compte des variations locales ni des structures internes de la tumeur. Ainsi, pour une caractérisation pertinente fondée sur les intensités, il serait nécessaire de recourir à des descripteurs de texture plus avancés, capables de capturer les motifs microstructuraux caractéristiques des lésions malignes.

## **IV.6 Discussion des Défis et Limitations de Notre Modèle:**

Bien que notre modèle CNN, basé sur l'architecture U-Net, ait démontré une excellente performance globale en matière de segmentation, comme en témoignent les valeurs élevées des indices de Dice et de Jaccard, plusieurs limites et défis doivent être soulignés afin d'envisager des pistes d'amélioration future.

Tout d'abord, le modèle reste fortement tributaire de la qualité et de la diversité du jeu de données utilisé lors de l'entraînement. Les images traitées proviennent d'une unique base de données, ce qui limite la capacité de généralisation du réseau à d'autres contextes cliniques (appareils d'imagerie différents, centres hospitaliers variés, cas atypiques). Une validation multi-centres, impliquant des données issues de différentes sources, serait indispensable pour évaluer la robustesse et la fiabilité clinique du modèle dans des situations réelles.

Ensuite, bien que les performances soient globalement élevées, le modèle présente des difficultés ponctuelles à segmenter les tumeurs malignes, notamment celles caractérisées par des contours flous, des formes très irrégulières, ou encore des extensions spiculées. Ces

configurations complexes peuvent conduire à une sous-segmentation ou à des erreurs de contour, altérant localement la précision du résultat. Cette limite souligne la difficulté du modèle à capturer les détails morphologiques fins, en particulier dans les zones de transition imprécise. L'intégration de modules d'attention ou de blocs multi-échelles pourrait constituer une solution prometteuse pour renforcer la sensibilité du modèle à ces structures subtiles.

Par ailleurs, le modèle actuel n'intègre pas de composante temporelle ni contextuelle, ce qui pourrait limiter ses performances dans le cas de séquences échographiques ou de situations nécessitant une cohérence inter-image, notamment en présence de bruit ou de variations physiologiques.

Enfin, le caractère boîte noire du modèle peut poser des problèmes d'interprétabilité et freiner son acceptation clinique. Pour favoriser son intégration dans le parcours de soin, l'ajout d'outils de visualisation des activations (ex. : cartes de chaleur, cartes de confiance) serait souhaitable afin de mieux comprendre les décisions du réseau et de renforcer la transparence des prédictions.

En résumé, bien que les résultats obtenus soient très encourageants, des améliorations sont envisageables au niveau de la généralisation, de la gestion des cas complexes, et de l'intégration clinique. Ces évolutions sont nécessaires pour faire de ce modèle un outil fiable et accepté dans la pratique médicale quotidienne.

#### **IV.7 Perspectives et Travaux Futurs :**

Améliorations possibles. Bien que notre modèle U-Net ait démontré de très bonnes performances en segmentation des tumeurs mammaires, plusieurs pistes d'amélioration peuvent être envisagées pour renforcer encore sa précision et sa robustesse. Tout d'abord, l'utilisation d'un jeu de données plus vaste et plus varié, incluant différentes résolutions d'image, des appareils échographiques variés et des cas cliniques plus hétérogènes, permettrait de mieux généraliser le modèle aux conditions réelles. De plus, l'exploration de variantes architecturales plus avancées, telles que Attention U-Net, HMA-Net ou ResU-Net, pourrait améliorer la détection des contours fins, notamment dans les cas de tumeurs malignes irrégulières. L'intégration de mécanismes d'attention ou de modules multi-échelles renforcerait

la capacité du modèle à se focaliser sur les régions les plus pertinentes, tandis que le développement de stratégies de fusion multi-modale (échographie + IRM ou mammographie, par exemple) ouvrirait la voie à une segmentation encore plus complète et précise.

Applications cliniques potentielles. Le travail présenté ici offre plusieurs opportunités d'intégration directe dans le flux de travail médical. Le modèle pourrait, par exemple, être intégré dans les logiciels d'imagerie médicale utilisés en routine pour fournir une aide à la décision aux radiologues, en proposant automatiquement une segmentation de la tumeur accompagnée d'indicateurs de forme (aire, circularité, solidité) et de scores de confiance. Il pourrait également servir d'outil de suivi longitudinal, en comparant les contours de la tumeur à différents moments pour détecter une progression, une régression ou une stabilité. De plus, une version embarquée de l'algorithme pourrait être implémentée sur les appareils d'échographie eux-mêmes, permettant une analyse automatique en temps réel, juste après l'acquisition de l'image.

Recherche future. Enfin, cette étude ouvre la voie à de nombreuses directions de recherche futures. L'une des plus évidentes est le développement d'un système combinant segmentation et classification automatique des tumeurs (bénignes vs malignes), qui serait particulièrement utile pour le tri des patients. D'autres travaux pourraient se concentrer sur la prédiction de la réponse au traitement à partir des caractéristiques segmentées (forme, taille, texture), ou sur l'intégration du modèle dans des réseaux décisionnels cliniques plus larges, intégrant données d'imagerie, cliniques et biologiques. L'objectif ultime serait de construire une intelligence artificielle multimodale et interprétable, agissant comme un véritable assistant numérique pour les oncologues et radiologues, dans la perspective d'une médecine plus personnalisée, rapide et efficace.

**IV.8 conclusion :**

Les résultats obtenus au cours de cette étape confirment la pertinence et l'efficacité de notre approche basée sur le modèle U-Net pour la segmentation automatique des tumeurs mammaires dans les images échographiques. Les métriques de performance élevées, notamment un Dice Score allant jusqu'à 0.9884 et un indice de Jaccard atteignant 0.9771, démontrent la robustesse du modèle pour délimiter précisément les régions tumorales, aussi bien dans les cas bénins que malins. De plus, les comparaisons systématiques avec des méthodes classiques telles que le region growing, k-means et les contours actifs ont mis en évidence la supériorité constante du CNN, en particulier dans les situations complexes où les autres approches échouent.

Ces résultats ont des implications significatives pour la pratique clinique : ils ouvrent la voie à l'intégration d'outils intelligents dans le flux de travail des radiologues, facilitant l'interprétation rapide des images et la détection précoce des anomalies. Sur le plan scientifique, ils constituent une base solide pour le développement futur de systèmes de diagnostic assisté par l'IA, capables d'associer segmentation, classification et prédiction de l'évolution tumorale.

Ces résultats prometteurs seront approfondis dans la conclusion générale de ce mémoire, où nous récapitulerons les principales contributions de notre travail, les limites identifiées et les perspectives de recherche ouvertes par cette étude dans le domaine de l'imagerie médicale assistée par intelligence artificielle.

# Conclusion générale

## Conclusion Générale :

Ce mémoire de fin d'étude a porté sur le développement d'une solution basée sur l'intelligence artificielle, et plus précisément sur le modèle U-Net, pour la segmentation automatique des tumeurs du sein à partir d'images échographiques. L'objectif principal a été d'améliorer la détection et la délimitation des lésions tumorales, en vue d'assister les professionnels de santé dans l'évaluation diagnostique du cancer du sein.

Dans le premier chapitre, nous avons d'abord abordé la problématique du cancer du sein, en mettant en lumière son ampleur mondiale et nationale, notamment en Algérie où il constitue la première cause de mortalité par cancer chez la femme. Nous avons présenté des statistiques récentes sur l'incidence et la mortalité, tout en exposant les moyens de prise en charge adoptés localement. Ensuite, nous avons détaillé les différents types de tumeurs et les méthodes médicales de classification, avant d'examiner le rôle fondamental des techniques d'imagerie médicale (échographie, mammographie, IRM) dans la détection précoce. Enfin, nous avons souligné l'importance cruciale de la segmentation des images médicales pour affiner les contours des lésions et ainsi améliorer la valeur du diagnostic.

Dans les chapitres suivants, nous avons montré comment l'informatique et les méthodes d'analyse d'image permettent d'augmenter la précision du diagnostic, en intégrant des algorithmes puissants. Nous avons présenté les avancées les plus récentes dans le domaine de l'apprentissage profond, avec un focus particulier sur les architectures CNN et notamment U-Net, largement utilisées pour la segmentation dans les images médicales.

Après une comparaison détaillée entre les méthodes classiques (région, contour actif, k-means) et notre modèle U-Net, les résultats ont clairement démontré la supériorité du deep learning, notamment en termes de Dice Score ( $> 0.98$ ) et d'indice de Jaccard ( $> 0.97$ ). Le modèle s'est révélé précis, robuste et performant, aussi bien dans la segmentation des lésions bénignes que malignes. Ces performances s'accompagnent également d'une extraction fiable des caractéristiques morphologiques, utiles à l'évaluation et au suivi de l'évolution tumorale.

Ce travail représente une avancée notable vers l'intégration de systèmes intelligents dans le flux de travail clinique. Il ouvre des perspectives prometteuses pour :

## **Conclusion générale**

- l'amélioration continue du modèle (ex. : attention, fusion multi-modale),
- l'aide au diagnostic assisté par IA,
- et le développement d'outils cliniques fiables pour la détection, la classification et le suivi des tumeurs mammaires.

Ainsi, cette étude pose les bases solides d'un système de diagnostic assisté par ordinateur, qui pourrait être intégré à terme dans les hôpitaux pour renforcer la prise en charge du cancer du sein en Algérie et ailleurs.

## bibliographie

- [1] Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249. <https://doi.org/10.3322/caac.21660>
- [2] Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A. (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 68(6), 394–424. <https://doi.org/10.3322/caac.21492>
- [3] Anderson, B. O., Ilbawi, A. M., & Fidarova, E. (2015). The global breast cancer initiative: A strategic collaboration to strengthen health care for non-communicable diseases. *Cancer*, 121(17), 3274–3282. <https://doi.org/10.1002/cncr.29559>
- [5] Shield, K. D., Soerjomataram, I., & Rehm, J. (2016). Alcohol use and breast cancer: A critical review. *Alcoholism: Clinical and Experimental Research*, 40(6), 1166–1181. <https://doi.org/10.1111/acer.13071>
- [7] Sankaranarayanan, R., Ramadas, K., Qiao, Y. L., et al. (2014). Managing the changing burden of cancer in Asia. *BMC Medicine*, 12, 3. <https://doi.org/10.1186/1741-7015-12-3>
- [9] Vaccarella, S., Laversanne, M., Ferlay, J., & Bray, F. (2017). Cervical cancer in Africa, Latin America and the Caribbean, and Asia: Regional inequalities and changing trends. *International Journal of Cancer*, 141(10), 1997–2001. <https://doi.org/10.1002/ijc.30901>
- [10] International Agency for Research on Cancer (IARC). (2021). *Cancer today – Data visualization tools for exploring the global cancer burden in 2020*. Lyon: WHO-IARC. <https://gco.iarc.fr/today>
- [11] Ministère de la Santé, de la Population et de la Réforme Hospitalière (Algérie). (2020). *Rapport national sur le cancer en Algérie*. Alger: Direction générale de la prévention.

## bibliographie

- [12] Benider, A., et al. (2018). Cancer incidence in Algeria: Results from population-based cancer registries. *International Journal of Cancer*, 143(7), 1768–1776. <https://doi.org/10.1002/ijc.31571>
- [13] World Health Organization (WHO). (2022). *Cancer Country Profiles 2022 – Algeria*. Genève: WHO. <https://www.who.int/cancer-country-profiles>
- [14] Bouchoucha, N., et al. (2019). Breast cancer in young Algerian women: Epidemiological and clinical characteristics. *Breast Cancer Research and Treatment*, 175(1), 215–222. <https://doi.org/10.1007/s10549-019-05146-y>
- [15] Lallaoui, H., et al. (2017). BRCA1 and BRCA2 mutations in Algerian breast/ovarian cancer families: First report and genetic counseling implications. *Breast Cancer Research and Treatment*, 162(2), 241–253. <https://doi.org/10.1007/s10549-016-4101-4>
- [16] Hamdi-Cherif, M., et al. (2020). Cancer incidence in Setif, Algeria: Updated results of a population-based cancer registry 1986–2015. *Cancer Epidemiology*, 65, 101693. <https://doi.org/10.1016/j.canep.2020.101693>
- [17] Ministère de la Santé, Algérie. (2016). *Plan national cancer 2015–2019*. Alger: Ministère de la Santé.
- [18] Lakhani, S. R., Ellis, I. O., Schnitt, S. J., Tan, P. H., & van de Vijver, M. J. (Eds.). (2012). *WHO Classification of Tumours of the Breast* (4th ed.). Lyon: International Agency for Research on Cancer.
- [19] Schnitt, S. J. (2010). Classification and prognosis of invasive breast cancer: From morphology to molecular taxonomy. *Modern Pathology*, 23(Suppl 2), S60–S64. <https://doi.org/10.1038/modpathol.2010.33>
- [20] Rakha, E. A., & Ellis, I. O. (2011). Modern classification of breast cancer: Should we stick with morphology or convert to molecular profile characteristics. *Advances in Anatomic Pathology*, 18(4), 255–267. <https://doi.org/10.1097/PAP.0b013e318220c005>
- [21] Perou, C. M., Sørlie, T., Eisen, M. B., et al. (2000). Molecular portraits of human breast tumours. *Nature*, 406(6797), 747–752. <https://doi.org/10.1038/35021093>

## bibliographie

- [22] Sørli, T., Perou, C. M., Tibshirani, R., et al. (2001). Gene expression patterns of breast carcinomas distinguish tumor subclasses with clinical implications. *Proceedings of the National Academy of Sciences*, 98(19), 10869–10874. <https://doi.org/10.1073/pnas.191367098>
- [23] Prat, A., & Perou, C. M. (2011). Deconstructing the molecular portraits of breast cancer. *Molecular Oncology*, 5(1), 5–23. <https://doi.org/10.1016/j.molonc.2010.11.003>
- [4] World Cancer Research Fund/American Institute for Cancer Research. (2018). *Diet, nutrition, physical activity and breast cancer: Continuous Update Project Expert Report*. <https://www.wcrf.org/diet-activity-and-cancer>
- [8] Marmot, M. G., Altman, D. G., Cameron, D. A., et al. (2013). The benefits and harms of breast cancer screening: An independent review. *British Journal of Cancer*, 108(11), 2205–2240. <https://doi.org/10.1038/bjc.2013.177>
- [29] American Cancer Society. (2022). *Breast Cancer Early Detection and Diagnosis*. <https://www.cancer.org/cancer/breast-cancer/screening-tests-and-early-detection.html>
- [30] Thiesse, P., et al. (2002). Comprendre l'échographie mammaire. *Bulletin du cancer*, 89(12), 1083. Centre Léon Bérard, Lyon.
- [31] Kanhai, R. C., Hage, J. J., van Diest, P. J., et al. (2000). Short-term and long-term histologic effects of castration and estrogen treatment on breast tissue of 14 male-to-female transsexuals in comparison with two chemically castrated men. *American Journal of Surgical Pathology*, 24, 74-80.
- [32] Sickles, E. A. (1986). Mammographic features of 300 consecutive non palpable breast cancers. *American Journal of Roentgenology*, 146, 661-663.
- [33] Feig, S. A. (1984). Radiation risk from mammography: Is it clinically significant? *American Journal of Roentgenology*, 143, 469-475.
- [34] Feig, S. A., & Ehrlich, S. M. (1990). Estimation of radiation risk from screening mammography: Recent trends and comparison with expected effects. *Radiology*, 174, 141-147.

## bibliographie

- [35] MacLelland, R., & Picasso, E. O. (1990). Issues in mammography. *Cancer*, 66, 1341-1343.
- [36] Shutterstock. (n.d.). *Mammography machine* [Image]. <https://www.shutterstock.com/search/mammography-machine>
- [37] DIA, O. (n.d.). *Apport de l'échographie dans le diagnostic d'un cancer du sein chez l'homme* [Mémoire universitaire].
- [38] Guyer, P. B., & Dewbury, K. C. (1988). Sonomammography in benign breast disease. *British Journal of Radiology*, 61, 374-378.
- [39] et [43] Sagbo, A. (1995). *Contribution de la mammographie et de l'échographie mammaire au dépistage des pathologies mammaires en République du Bénin : étude faite au CAR* [Mémoire de fin de cycle]. UAC / CPU.
- [40] Référence Médico SARL. (n.d.). *Appareil d'échographie BLS-810*. <https://www.referencemedicosarl.com/product/appareil-dechographie-bls-810/>
- [41] Hantzo, S., Da Silva, D., & Saillant, E. (2005). IRM mammaire et stratégies antiangiogéniques. *British Journal of Cancerology*, 90, 1-7.
- [42] Centre d'Imagerie Médicale du Grésivaudan. (n.d.). [Nom et date de la publication manquants].
- [44] MedicalExpo. (n.d.). *QuantumCam*. <https://www.collinsdictionary.com/dictionary/french-english/manquant>.
- [48] Kuhl, C. K. et al. (2014). MRI for diagnosis of pure ductal carcinoma in situ: a prospective observational study. *The Lancet Oncology*, 15(4), 369-370.
- [51] Kuhl, C. K. et al. (2014). MRI for breast cancer screening: Systematic review and meta-analysis. *European Radiology*, 24(10), 2419-2435.
- [24] Allemani, C., Matsuda, T., Di Carlo, V., et al. (2018). Global surveillance of trends in cancer survival 2000–14 (CONCORD-3): analysis of individual records for 37 513 025 patients diagnosed with one of 18 cancers from 322 population-based registries in 71 countries. *The Lancet*, 391(10125), 1023–1075. [https://doi.org/10.1016/S0140-6736\(17\)33326-3](https://doi.org/10.1016/S0140-6736(17)33326-3)

## bibliographie

- [25] Berry, D. A., Cronin, K. A., Plevritis, S. K., et al. (2005). Effect of screening and adjuvant therapy on mortality from breast cancer. *New England Journal of Medicine*, 353(17), 1784–1792. <https://doi.org/10.1056/NEJMoa050518>
- [26] Early Breast Cancer Trialists' Collaborative Group (EBCTCG). (2011). Relevance of breast cancer hormone receptors and other factors to the efficacy of adjuvant tamoxifen: patient-level meta-analysis of randomised trials. *The Lancet*, 378(9793), 771–784. [https://doi.org/10.1016/S0140-6736\(11\)60993-8](https://doi.org/10.1016/S0140-6736(11)60993-8)
- [27] Yabroff, K. R., Lund, J., Kepka, D., & Mariotto, A. (2011). Economic burden of cancer in the United States: estimates, projections, and future research. *Cancer Epidemiology, Biomarkers & Prevention*, 20(10), 2006–2014. <https://doi.org/10.1158/1055-9965.EPI-11-0650>
- [28] Independent UK Panel on Breast Cancer Screening. (2012). The benefits and harms of breast cancer screening: an independent review. *The Lancet*, 380(9855), 1778–1786. [https://doi.org/10.1016/S0140-6736\(12\)61611-0](https://doi.org/10.1016/S0140-6736(12)61611-0)
- [45] Pham, D. L., Xu, C., & Prince, J. L. (2000). Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*, 2, 315–337.
- [46] Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson.
- [47] et [53] Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- [49] et [52] Ferreira, J. R. et al. (2020). Deep Learning in Breast Cancer Imaging: A Review. *IEEE Access*, 8, 178783-178795.
- [50] Dhungel, N., et al. (2017). Automated mass detection in mammograms using deep learning and random forests. *Journal of Digital Imaging*, 30(4), 481-490.
- [54] et [58] et [61] Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing*. Pearson Education.
- [55] Achim, A., Bezerianos, A., & Tsakalides, P. (2001). Bayesian multiscale speckle removal. *IEEE Transactions on Medical Imaging*, 20(9), 877-889.

## bibliographie

- [56] Perona, P., & Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(7), 629-639.
- [57] Zuiderveld, K. (1994). Contrast-limited adaptive histogram equalization. In *Graphics Gems IV* (pp. 474-485). Academic Press.
- [59] et [64] Pham, D. L., Xu, C., & Prince, J. L. (2000). Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*, 2(1), 315-337.
- [60] Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221-248.
- [62] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.
- [63] Adams, R., & Bischof, L. (1994). Seeded region growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(6), 642-647.
- [65] Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snakes: Active contour models. *International Journal of Computer Vision*, 1(4), 321-331.
- [66] Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 679-698.
- [67] Gillies, R. J., Kinahan, P. E., & Hricak, H. (2016). Radiomics: Images are more than pictures, they are data. *Radiology*, 278(2), 563-577. <https://doi.org/10.1148/radiol.2015151169>
- [68] Chen, M., Tustison, N. J., Jena, R., & Gee, J. C. (2023). Image registration: Fundamentals and recent advances based on deep learning. In D. Shen & G. Wu (Eds.), *Machine Learning for Brain Disorders* (pp. 435-458). Academic Press. <https://doi.org/10.1016/B978-0-323-85738-4.00014-1>
- [69] Crum, W. R., Hartkens, T., & Hill, D. L. G. (2004). Non-rigid image registration: Theory and practice. *The British Journal of Radiology*, 77(suppl\_2), S140-S153. <https://doi.org/10.1259/bjr/25329214>

## bibliographie

- [70] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [71] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- [72] et [73] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Medical Image Computing and Computer-Assisted Intervention (MICCAI)* (pp. 234-241). Springer, Cham.
- [74] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2961–2969. <https://doi.org/10.1109/ICCV.2017.322>
- [75] Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495.
- [76] Abdel-Nasser, M., & Moussa, M. (2020). DBU-Net: Dual branch U-Net for tumor segmentation in breast ultrasound images. *Computer Methods and Programs in Biomedicine*, 194, 105530.
- [77] Zhu, J., Li, Y., Wang, X., Wang, Y., & Wei, X. (2024). Segmentation of cancer masses on breast ultrasound images using modified U-Net. *Journal of Medical Imaging and Health Informatics*, 14(1), 101-106.
- [78] Jin, Y., Dong, Q., Zheng, H., Zhou, B., & Zhang, Y. (2025). HMA-Net: A hybrid mixer framework with multihead attention for breast ultrasound image segmentation. *BioMedical Engineering OnLine*, 24(1), 1-19.
- [79] Li, C., Chen, J., Li, Y., Chen, J., & Ma, X. (2025). A Cross-scale Attention-Based U-Net for Breast Ultrasound Image Segmentation. *BioMedical Engineering OnLine*, 24(1), 1-20.
- [80] Ding, T., Shi, K., Pan, Z., & Ding, C. (2024). AI-based automated breast cancer segmentation in ultrasound imaging based on Attention Gated Multi ResU-Net. *PeerJ Computer Science*, 10, e2226. <https://doi.org/10.7717/peerj-cs.2226>

## bibliographie

- [81] Zhou, X., Huang, Z., Zhu, H., Yao, Q., & Zhou, S. K. (2024). Hybrid Attention Network: An efficient approach for anatomy-free landmark detection. *arXiv preprint arXiv:2412.06499*.
- [82] Islam, M. R., Rahman, M. M., Ali, M. S., et al. (2024). Enhancing breast cancer segmentation and classification: An Ensemble Deep Convolutional Neural Network and U-Net approach on ultrasound images. *Machine Learning with Applications*, 16, 100555. <https://doi.org/10.1016/j.mlwa.2024.100555>
- [83] Wei, J., Zhang, H., & Xie, J. (2024). A novel deep learning model for breast tumor ultrasound image classification with lesion region perception. *Current Oncology*, 31(9), 5057–5079. <https://doi.org/10.3390/curroncol31090374>
- [84] Long, B., Guan, Y., & Holden, M. (2023). A two-stage neural network model for breast ultrasound image classification. In *Proceedings of the IEEE 23rd International Conference on Bioinformatics and Bioengineering (BIBE)* (pp. 129–133).
- [85] Yang, H., & Yang, D. (2023). CSwin-PNet: A CNN–Swin Transformer combined pyramid network for breast lesion segmentation in ultrasound images. *Expert Systems with Applications*, 213, 119024. <https://doi.org/10.1016/j.eswa.2022.119024>
- [86] Walid Al-Dhabyani, Mohammed Gomaa, Hussien Khaled, Fahmy Aly, “Deep learning approaches for data augmentation and classification of breast masses using ultrasound images”, *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 10, no. 5, 2019. DOI: 10.14569/IJACSA.2019.0100579
- [87] Medixant, *RadiAnt DICOM Viewer*, 2018. Disponible sur : <https://www.radiantviewer.com>
- [88] Śmieszny, *Fast Photo Crop*, 2013. Disponible sur : <https://www.microsoft.com/ar-eg/p/fast-photo-crop/9wzdncrdnvpv?activetab=pivot%3Aoverviewtab>
- [89] *MATLAB and Statistics Toolbox Release*, The MathWorks, Inc., Natick, Massachusetts, United States, 2015.