

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université De Echahid Echeikh Larbi Tébessi-Tébessa



Faculté des Sciences Exactes et Sciences de la Nature et de la Vie

Département d'informatique

Laboratoire de domiciliation : Laboratoire de Mathématique, Informatique et Systèmes
(LAMIS)

THÈSE

Présentée et Soutenue Publiquement En vue de l'obtention du diplôme de

Doctorat 3^{ème} Cycle L.M.D. en Informatique

Option : Systèmes d'Information

Par:

SOLTANI HAMA

Intitulée

**Détection du Cancer du Sein et Classification par une
Approche intelligente**

Soutenue le : 01/02/2025

Devant le jury :

Hakim Bendjenna	Prof	Président	Université De Tébessa
Makhlouf Derdour	Prof	Examineur	Université D'Oum EL bouaghi
Mohamed Ridda Laouar	Prof	Examineur	Université De Tébessa
Mohamed Amroune	Prof	Directeur de Thèse	Ecole supérieur du Nano Science & Nano Technologie Alger
Issam Bendib	MCA	Co-Directeur de Thèse	Université De Tébessa

Année Universitaire : 2024-2025

Dédicace

Dédié à l'âme de mon père bien-aimé, dont l'amour inconditionnel, l'affection, le soutien et les prières ont été ma force et mon guide en toutes circonstances. À ma mère, source inépuisable de motivation, à mes chères sœurs pour leur soutien indéfectible, à mes frères, et à mes amis.



Remercîment

Je souhaite exprimer ma profonde gratitude à mon superviseur, le Professeur AMROUNE Mohamed, de l'Ecole supérieure de Science de Nano & Nanotechnologie à Alger, pour son orientation et son soutien inestimables tout au long de mes années de recherche. Sa contribution à mon projet, sa confiance et son encouragement ont été cruciaux pour l'aboutissement de ce travail. Je tiens également à adresser mes sincères remerciements à mon co-superviseur, le Dr. BENDIB Issam, ainsi qu'au Dr. HAOUAM Mohamed-Yassine, pour leur guidance experte, leur motivation constante et leur disponibilité sans faille durant ce parcours de recherche.

Je souhaite exprimer ma sincère reconnaissance envers le Professeur BENDJENNA Hakim, directeur du laboratoire LAMIS et enseignant à l'Université Larbi Tébessi – Tébessa, pour avoir accepté d'examiner et d'évaluer ce travail. Sa disponibilité pour des discussions scientifiques enrichissantes a grandement contribué à l'avancement de cette recherche.

Que Pr. LAOUER Mohamed Ridda, Professeur à l'Université Larbi Tébessi – Tébessa et Pr. DERDOUR Makhoulf de l'Université Oun Ebouaghi, reçoivent ma sincère sollicitude pour avoir bien voulu faire partie de ce jury, avec qui c'est un privilège de pouvoir partager notre travail.

Je remercie tous mes collègues et amis du laboratoire LAMIS pour l'aide qu'ils m'ont apportée.

Je tiens aussi à remercier ceux qui, dans des périodes plus difficiles, ont été là pour lire notre travail et m'aider à avancer.

Je souhaite aussi remercier mes pairs et tous ceux qui ont contribué à l'amélioration de notre travail par leurs revues et suggestions critiques.

Enfin, ma gratitude va à ma famille et mes amis pour leur soutien émotionnel et encouragements qui ont été un réconfort dans les moments difficiles.



الملخص

يُعد سرطان الثدي أكبر هاجس لدى النساء في جميع أنحاء العالم بسبب عدد الوفيات التي يسببها، مما يستدعي وجود أدوات تشخيصية فعالة ودقيقة. تركز أطروحتنا على دمج تقنيات التعلم العميق الجديدة في الأنظمة المساعدة بالحاسوب للتشخيص السريع لسرطان الثدي الناتج عن الكتل الثديية. الهدف الرئيسي هو تطوير نظام قوي لاكتشاف وتصنيف الكتل الثديية مخصص لصور التصوير الشعاعي للثدي، بالاستفادة من قدرات التعلم العميق. النظام المقترح يتكون من وحدتين رئيسيتين: اكتشاف الكتل الثديية وتقسيمها، وتصنيف الكتل الثديية. وحدة الاكتشاف تدمج تقنية Mask R-CNN، وهي طريقة متقدمة لتجزئة الكائنات، لتحسين أداء الاكتشاف مع تقليل تكاليف التدريب وتقليل الإيجابيات الكاذبة. تعزز هذه الطريقة دقة وكفاءة اكتشاف الكتل الثديية، مما يضع النظام في طليعة تقنيات التشخيص الحالية. في وحدة التصنيف، يتم اقتراح استخدام النماذج المدربة مسبقًا لاستغلال ميزات التعلم العميق المكتسبة من مجموعات بيانات أخرى، مما يحسن دقة تصنيف الكتل الثديية. هذه الطريقة في التعلم بالنقل لا تعزز الأداء فحسب، بل تسهل أيضًا التدريب السريع والتكيف مع البيانات الجديدة. مساهمة بارزة في هذه الأطروحة هي إنشاء قاعدة بيانات جديدة للتصوير الشعاعي للثدي الرقمي، وهي الأولى من نوعها التي تنشأ في الجزائر، وتسمى LAMIS-DBDM. تشكل هذه القاعدة موردًا قيمًا لتطوير واختبار أدوات التشخيص المتقدمة والخوارزميات المصممة خصيصًا للسكان الجزائريين. تضم هذه القاعدة بيانات جينية وديموغرافية متنوعة، مما يمكن من فهم أفضل للأنماط والشذوذات الخاصة بالمنطقة. تملك هذه المبادرة القدرة على تحسين دقة اكتشاف وعلاج سرطان الثدي، مما يؤدي إلى حلول رعاية صحية أكثر تخصيصًا وفعالية. تم تقييم النظام المطور بدقة على مجموعات بيانات عامة، مما أظهر أداءً متفوقًا مقارنة بالطرق الرائدة في المجال. في عدة حالات، تفوق النظام على التقنيات الموجودة، مما يبرز إمكاناته كأداة موثوقة لتشخيص سرطان الثدي. لا تقتصر هذه الأطروحة على تطوير مجال تشخيص سرطان الثدي فحسب، بل تساهم أيضًا في المجتمعات الطبية والبحثية العالمية من خلال توفير مجموعة بيانات فريدة وتعزيز التعاون الدولي. تمهد الأفكار والتقنيات المطورة هنا الطريق للابتكارات المستقبلية في التصوير الطبي والذكاء الاصطناعي، بهدف نهائي هو تحسين نتائج المرضى وتقليل الوفيات المرتبطة بسرطان الثدي.

الكلمات المفتاحية:

سرطان الثدي، التعلم العميق، التصوير الشعاعي للثدي الرقمي، تصنيف السرطان و اكتشاف ،

Abstract

Breast cancer is a leading cause of morbidity and mortality among women worldwide, necessitating efficient and accurate diagnostic tools. Ours thesis focuses on integrating novel deep learning techniques into computer-aided systems for the rapid diagnosis of breast cancer caused by breast masses. The primary objective is to develop a robust breast mass detection and classification system specifically for mammography images, leveraging the capabilities of deep learning. The proposed system is structured into two key modules: breast mass detection and segmentation, and breast mass classification. The detection module incorporates Mask R-CNN, an advanced instance segmentation method, to improve detection performance while reducing training costs and minimizing false positives. This method enhances the accuracy and efficiency of detecting breast masses, positioning the system at the forefront of current diagnostic technologies. In the classification module, the use of pretrained models is proposed to exploit deep learning features acquired from other datasets, thereby enhancing the classification accuracy of breast masses. This transfer learning approach not only boosts performance but also facilitates faster training and adaptation to new data. A notable contribution of this thesis is the creation of LAMIS-DBDM a novel digital mammography dataset, the first of its kind originating from Algeria. This dataset is a valuable resource for developing and testing advanced diagnostic tools and algorithms tailored to the Algerian population. It incorporates diverse genetic and demographic data, enabling a better understanding of region-specific patterns and anomalies. This initiative holds the potential to improve the accuracy of breast cancer detection and treatment, leading to more personalized and effective healthcare solutions. The developed system was rigorously evaluated on public datasets, demonstrating superior performance compared to state-of-the-art methods. In several cases, the system outperformed existing technologies, underscoring its potential as a reliable tool for breast cancer diagnosis. This thesis not only advances the field of breast cancer diagnostics but also contributes to the global medical and research communities by providing a unique dataset and fostering international collaborations. The insights and technologies developed herein pave the way for future innovations in medical imaging and artificial intelligence, ultimately aiming to enhance patient outcomes and reduce breast cancer-related mortality.

Key words:

Breast cancer, Mammogram, Mass detection, CAD, Transfer Learning.

Résumé

Le cancer du sein représente une préoccupation majeure en matière de morbidité et de mortalité chez les femmes à l'échelle mondiale, ce qui souligne l'urgence d'outils de diagnostic à la fois efficaces et précis. Cette thèse s'attache à l'intégration de nouvelles approches d'apprentissage profond dans les systèmes d'aide au diagnostic, visant à une détection rapide du cancer du sein lié aux masses mammaires. L'objectif principal est de concevoir un système robuste capable de détecter et de classifier les masses mammaires dans les images mammographiques, en exploitant les atouts de l'apprentissage profond. Le système proposé se divise en deux modules essentiels : la détection et la segmentation des masses mammaires, ainsi que la classification de ces masses. Le module de détection utilise Mask R-CNN, une méthode de segmentation d'instances avancée, pour optimiser les performances de détection tout en réduisant les coûts d'entraînement et en diminuant le nombre de faux positifs. Cette approche améliore significativement la précision et l'efficacité de la détection des masses mammaires, plaçant le système à l'avant-garde des technologies de diagnostic actuelles. Quant au module de classification, il propose d'utiliser des modèles pré-entraînés pour tirer parti des caractéristiques d'apprentissage profond acquises sur d'autres ensembles de données, ce qui rehausse la précision dans la classification des masses mammaires. Cette méthode d'apprentissage par transfert permet non seulement d'améliorer les performances, mais également de rendre l'entraînement plus rapide et l'adaptation aux nouvelles données plus facile. Une contribution majeure de cette thèse est participation à la création de LAMIS-DBDM, un nouvel ensemble de données mammographiques numériques, le premier de ce type en provenance d'Algérie. Cet ensemble de données constitue une ressource précieuse pour le développement et la validation d'outils diagnostiques avancés et d'algorithmes adaptés à la population algérienne. Il intègre des données génétiques et démographiques variées, facilitant ainsi une meilleure compréhension des motifs et des anomalies spécifiques à la région. Cette initiative a le potentiel d'améliorer la précision dans la détection et le traitement du cancer du sein, contribuant à des solutions de soins de santé plus personnalisées et efficaces. Le système développé a été soumis à une évaluation rigoureuse sur des ensembles de données publiques, montrant des performances supérieures à celles des méthodes de pointe. Dans plusieurs cas, il a surpassé les technologies existantes, mettant en avant son potentiel en tant qu'outil fiable pour le diagnostic du cancer du sein. Cette thèse ne se limite pas à faire progresser le domaine du diagnostic du cancer du sein, mais elle enrichit également les communautés médicales et de recherche internationales en proposant un ensemble de données unique et en favorisant les collaborations mondiales. Les connaissances et technologies développées dans le cadre de ce travail ouvrent la voie à de futures innovations en imagerie médicale et en intelligence artificielle, visant à améliorer les résultats pour les patients et à réduire la mortalité liée au cancer du sein.

Les mots clés :

Cancer du sein, mammographie, détection du mass, DAO, Apprentissage par Transfert

Table des Matières

Table des Matières	vi
Liste de Tableaux	ix
Liste de Figures.....	x
Introduction Générale	1
1. Contexte & Problématique :.....	2
2. Dessein et Objectifs	4
3. Contributions.....	5
4. Plan de lecture de la thèse	6
CHAPITRE I : Contexte Médical des Cancer du sein	8
1. Introduction au Cancer du Sein.....	9
1.1. Généralité sur le Tissu Normale du Sein :.....	9
1.2. Anatomie du Sein :.....	10
1.3. Comprendre le Cancer du Sein :	11
1.4. Les Facteurs De Risques Du Cancer Du Sein :.....	12
1.5. Méthodes de dépistage et de diagnostic :.....	13
1.6. La Prévention du Cancer du Sein :.....	14
2. Imagerie Médical	15
2.1. Mammographie Numérique :.....	15
2.2. Interprétation des mammographies	16
2.2.1. Classification BI-RADS.....	16
2.2.2. La Densité mammaire	17
2.2.3. Anomalies Identifiable par la Mammographie	18
2.2.4. Les défis des radiologues dans l'interprétation des mammographies.....	21
3. Les bases de données de mammographie.....	21
3.1. Importance des bases de données mammographiques	21
3.2. Généralités sur Les Bases de Données Mammographiques.....	22
3.3. Les Bases de Données Mammographiques existants.....	23
3.3.1. MIAS.....	23

3.3.2.	CBIS-DDSM.....	24
3.3.3.	INbreast.....	25
3.3.4.	BCDR.....	25
3.3.5.	OPTIMAM (OMI-DB)	26
3.3.6.	VinDr-Mammo.....	26
3.3.7.	EMBED.....	27
3.4.	Analyse comparative des caractéristiques des bases de données	28
4.	Conclusion	31
CHAPITRE II : Diagnostic Assisté par Ordinateur pour le Cancer du Sein		32
1.	Introduction.....	33
2.	Vision par ordinateur dans l'Analyse d'Images Médicales	34
3.	Détection et Diagnostic Assistés par Ordinateur (DAO) du Cancer du Sein	35
3.1.	Les systèmes de DAO	35
3.2.	Évolution des systèmes DAO	36
3.3.	Analyse comparative des systèmes DAO traditionnels et basés sur l'IA	36
3.4.	Les étapes des systèmes DAO	37
3.4.1.	Prétraitement des images	37
3.4.2.	Détection et segmentation.....	38
3.4.3.	Classification des anomalies	39
4.	Revue de la Littérature du DAO du Cancer du Sein	40
4.1.	Travaux sur la Détection des Masses	41
4.1.1.	Méthodes Traditionnel & Basées sur l'Apprentissage Automatique	41
4.1.2.	Méthodes Basées sur l'Apprentissage profond.....	42
4.2.	Travaux sur la Segmentation des Masses.....	44
4.2.1.	Méthodes de Segmentation Classique.....	45
4.2.2.	Méthodes de Segmentation Basées sur l'Apprentissage Profond.....	47
4.3.	Travaux sur la Classification des Masses.....	49
4.3.1.	Techniques Basées sur apprentissage automatique :	50
4.3.2.	Techniques Basées sur l'Apprentissage profond :	53
5.	Conclusion	55
CHAPITRE III : Contribution au Détection du Cancer du Sein et Classification		57
1.	Introduction.....	58
2.	Détection et Segmentation Automatique du Mass mammaire	60
2.1.	Prétraitement des Données.....	60
2.2.	Détection et Segmentation des Masses Mammaire avec MASK-RCNN.....	63
2.2.1.	Présentation du Mask RCNN.....	63

2.2.2.	Évolution des Techniques : De RCNN à Mask RCNN	64
2.2.3.	Le processus de Mask RCNN	66
3.	Classification des Masses Mammaires.....	67
3.1.	Prétraitement des Bases de Données.....	68
4.	Expérimente et Résultats.....	71
4.1.	Base de données utilisée	71
4.2.	Évaluation et Performances	72
4.3.	Détection et Segmentation	73
4.4.	Classification de masses.....	75
4.5.	Discussion	77
5.	Conclusion	78
CHAPITRE IV : LAMIS-DMDB.....		79
La Base de Données Algérienne de Mammographie		79
1.	Introduction.....	80
1.	La Base de Données LAMIS-DMDB : Méthodes et Matériels	81
1.1.	Acquisition de la Base de Données LAMIS-DMDB	81
1.2.	L'importance du développement de la base	82
1.3.	Construction de LAMIS-DMDB	83
1.4.	Métadonnées de LAMIS-DMDB.....	85
1.5.	Description de la LAMIS-DMDB.....	85
2.	LAMIS-DMDB pour les Méthodes de ML et DL.....	87
2.1.	Stratégies de Classification par Apprentissage Profond	87
2.1.1.	Méthodes et Matériels	87
2.1.2.	Expérimentations et Résultats	89
2.2.	Stratégies de Classification par Apprentissage par transfert.....	91
2.2.1.	Méthodes et Matériels	91
2.2.2.	Expérimentations et Résultats	92
3.	Plateforme Collaborative pour des Annotations Améliorées des Mammographies	95
4.	Conclusion	98
Conclusion Générale & Perspective		99
Bibliographie.....		102

Liste de Tableaux

CHAPITRE I

Tableau I. 1: le système de classification BI-RADS établi par ACR.....	17
Tableau I. 2: Caractéristiques techniques et descriptives des bases de données mammographiques	29
Tableau I. 3:Caractéristiques d'annotation et d'accessibilité	30

CHAPITRE II

Tableau II. 1:Les techniques de détection des masses basées sur l'apprentissage automatique.....	43
Tableau II. 2:Les techniques de détection des masses basées sur l'apprentissage profond	44
Tableau II. 3:Les techniques de segmentation des masses utilisant des Méthodes Classique	47
Tableau II. 4:Les méthodes de segmentation basée sur l'apprentissage profond	48
Tableau II. 5: Les méthodes de classification basée sur l'apprentissage automatique	51
Tableau II. 6 : Les méthodes de classification basée sur l'apprentissage profond	54

CHAPITRE III

Tableau III. 1 : Techniques d'Augmentation de Données Appliquées.....	73
Tableau III. 2: Performance de Détection du masses et Segmentation.....	74
Tableau III. 3 : hyperparamètres utilisés.....	76
Tableau III. 4:Performance de classification des masses mammaire.....	76
Tableau III. 5 : Comparaison des Méthodes de Détection, Segmentation et Classification	77

CHAPITRE IV

Tableau IV. 1: Description des couches de modèle CNN	89
Tableau IV. 2:Performance des modèles dans les différents scénarios	92

Liste de Figures

CHAPITRE I

Figure I. 1: L'anatomie du sein	10
Figure I. 2: Représentation graphique des stades du cancer ;	11
Figure I. 3: Les facteurs de risque pour le cancer du sein.....	12
Figure I. 4: La machine de mammographie et l'opération de prendre des images mammaires.	15
Figure I. 5: Les différents éléments de l'image de mammographie numérique appartenant à l'ensemble de données LAMISDMDB	16
Figure I. 6 : les diverses catégories de densité pour la mammographie numérique. Les images dans la figure appartiennent à l'ensemble de données LAMISDMDB.....	18
Figure I. 7: Un volume asymétrique bénin du tissu mammaire (flèches) est visible dans la partie supérieure du sein gauche. (A): MLO, (B): CC; R: droite, L: gauche	19
Figure I. 8: Exemple d'une distorsion architecturale sur une image mammographique avec un zoom avant	19
Figure I. 9: (A) Mammographie d'une femme présentant des microcalcifications (MC) et un amas de microcalcifications (MCC). (B) Région agrandie marquée par le carré rouge dans A, montrant des MC et un MCC. (C) La région en B avec un marquage précis des emplacements des MC et du MCC.	20
Figure I. 10: La figure représente la caractérisation des calcifications en fonction de la distribution.	20
Figure I. 11: (A) Mammographie d'une femme avec des masses bénignes et suspectes. (B) Région agrandie marquée par le carré rouge dans A, montrant les masses. (C) La région en B avec un marquage précis des emplacements des masses (vert pour bénin, rouge pour suspect).....	20
Figure I. 12: La figure représente la caractérisation des masses en fonction de la forme et des limites	20
Figure I. 13: : figure représente les éléments inutiles et les erreurs de positionnement	23

CHAPITRE II

Figure II. 1: Les phases essentielles d'un DOA pour cancer du sein	37
--	----

CHAPITRE III

Figure III. 1: processus général Pour La détection et classification du masses mammaires	59
Figure III. 2: Le processus complet de prétraitement	61

Figure III. 3: Fichier d'annotation format liste de propriétés	62
Figure III. 4:Fichier d'annotation format COCO.....	62
Figure III. 5:Exemple des techniques d'augmentations applique sur la mammographie	62
Figure III. 6: Le processus de détection et segmentation des masses mammaires avec Mask RCNN	63
Figure III. 7: Architecture Générale du Mask-RCNN	64
Figure III. 8: Processus e classification des masses mammaires	68
Figure III. 9: Exemple des masses extraits	70
Figure III. 10: Détails de la base de données INbreast	71
Figure III. 11: Échantillon de la base de données INbreast	72
Figure III. 12 : Résultat de Détection et de Segmentation	75
Figure III. 13:Courbes de pertes d'entraînement et de test	77

CHAPITRE IV

Figure IV. 1: Exemple annoté montrant la bordure d'une masse maligne hautement suspecte (couleur cyan) et une zone de structures mammaires à surveiller (couleur verte) d'une incidence MLO de la base de données LAMIS-DMDB.....	84
Figure IV. 2:Exemple annoté montrant la bordure d'une masse maligne hautement suspecte et une zone de structures mammaires à surveiller d'une incidence craniocaudale de la base de données LAMIS-DMDB. ...	84
Figure IV. 3:Processus de construction la base de données LAMIS-DMDB	84
Figure IV. 4: Statistique de la base de données LAMIS-DMDB	86
Figure IV. 5:Processus de Classification binaire.....	87
Figure IV. 6:Processus de Classification Multi class	88
Figure IV. 7:courbe de perte de classification binaire.....	90
Figure IV. 8:courbe de perd de classification multi classes	90
Figure IV. 9:Processus détaillé de classification de mammographie avec Apprentissage par Transfer.....	91
Figure IV. 10:Courbes de Perte et de Accuracy pour tous les Modèles Pré-entraînés VGG16, ResNet50 et EfficientNetB7 sur Différents Scénarios Expérimentaux	94
Figure IV. 11:Fenêtre d'accueil de la Plateforme d'annotation de LAMIS-DMDB	95
Figure IV. 12 : Fenêtre d'annotation de la Plateforme d'annotation de LAMIS-DMDB	95
Figure IV. 13: Application de notre système en tant qu'outil d'annotation sur LAMIS-DMDB.....	97

Liste des Abréviations

ACR: American College of Radiology
AES: Auto Examen Des Seins
ANN: Artificial Neurons Network
BIRADS: Breast Imaging Reporting And Data System
CAD: Computer Aided Diagnosis
CC: Craniocaudal View
CGAN: Conditional Generative Adversarial Networks
CNN: Convolutional Neural Network
CSV: Comma-Separated Values
CV: Computer Vision
DAO: Diagnostic/Detection Assisté Par Ordinateur
DICOM: Digital Imaging And Communications In Medicine
DL: Deep Learning
ECS : Examen Clinique Des Seins
ELM: Extreme Learning Machine
FCN: Fully Convolution Neural Network
FFDM: Full Field Digital Mammography:
FPN: Features Pyramids Network
GAN: Generative Adversarial Networks
HOG: Histogram Of Oriented Gradients
IA: Intelligent Artificial
IRM : Imagerie Par Résonance Magnétique
LBP : Local Binary Patterns
ML: Machine Learning
MLO: Mediolateral Oblique View

MLP: Multi-Perceptron

RCNN: Region-Based Convolutional Neural Networks

RF: Random Forest

ROI: Region Of Interest

RPN: Region Proposal Network

SFM: Scanned Film Mammography

SVM: Support Vector Machine

YOLO: You Only Look Once

Introduction Générale



Introduction Générale

1. Contexte & Problématique :

La détection du cancer du sein s'est imposée comme l'un des enjeux de santé majeurs à l'échelle mondiale, affectant des millions de personnes. Ces dernières années, le taux d'incidence de cette maladie a connu une hausse constante. Néanmoins, la morbidité associée au cancer du sein demeure relativement faible à l'échelle mondiale, grâce aux efforts de dépistage précoce[1]. Les manifestations cliniques du cancer du sein peuvent être classées en plusieurs catégories, incluant la distorsion architecturale, l'asymétrie, les microcalcifications et les masses. Parmi ces symptômes, la masse mammaire est considérée comme le signe le plus évident et le plus significatif comparé aux autres anomalies. Pour le dépistage précoce du cancer du sein, il existe de nombreuses techniques telles que les techniques d'imagerie et la biopsie. Les techniques d'imagerie comprennent l'échographie mammaire, l'IRM mammaire et la mammographie qui peuvent montrer les changements internes du sein via des instruments d'imagerie spécifiques.[2, 3] L'échographie mammaire examine les zones à l'intérieur du sein par sonogrammes pour former des images tandis que l'IRM mammaire peut fournir des images plus détaillées des zones du sein à l'intérieur du sein. La mammographie peut servir de version plus détaillée de la radiographie lorsque des anomalies sont trouvées dans les seins. Parmi toutes ces techniques d'imagerie, la mammographie est considérée comme la plus préférable en termes de commodité et de rentabilité. Du point de vue de la précision diagnostique, la biopsie, qui prend des tissus ou du liquide mammaire du sein pour une analyse pathologique, est le meilleur choix. Dans les procédures de biopsie, des pathologistes expérimentés examinent la biopsie sous un microscope et des analyses plus sophistiquées peuvent être effectuées. Par conséquent, la biopsie est la méthode la plus efficace pour la détection du cancer du sein. Cependant, un inconvénient de la biopsie est qu'il s'agit d'une méthode invasive car les patients doivent subir une période d'extraction douloureuse des tissus. De plus, les patients doivent attendre relativement plus longtemps que pour les méthodes basées sur l'imagerie car des expériences cliniques doivent être effectuées tandis que la méthode basée sur l'imagerie peut être inspectée à l'œil nu. En tenant compte de tous ces facteurs, la mammographie a joué un rôle clé dans la détection précoce du cancer du sein[4]. Cependant, l'interprétation manuelle des mammographies peut être chronophage et sujette aux erreurs en raison de la complexité des tissus mammaires et de facteurs manuels tels que la distraction et la fatigue. En conséquence, les systèmes d'aide à la décision peuvent fonctionner comme des assistants auxiliaires pour l'interprétation mammographique.

Généralement, chaque sein est imagé à partir de quatre angles différents, y compris LCC, LMLO, RCC et RMLO, lors du test de mammographie. Quatre vues permettent d'examiner pleinement le sein sous différents angles et positions pour une meilleure détection des anomalies. Le sein ressemble à une sphère dans les mammographies en vue CC tandis qu'il

ressemble davantage à un objet de forme triangulaire dans les mammographies en vue MLO en raison des positions des patients lorsque les images ont été prises[5]. La principale différence entre la vue CC et la vue MLO des mammographies est la présence du muscle pectoral. Dans les mammographies en vue CC, le muscle pectoral n'est généralement pas visible ou seule une petite partie est présentée sur le bord interne du sein. Cependant, le muscle pectoral est généralement situé aux coins supérieurs dans les mammographies en vue MLO avec des tailles et des emplacements variés, où il peut être facilement classé à tort comme des tissus fibroglandulaires. De plus, les régions musculaires pectorales peuvent être utiles pour l'analyse auxiliaire des anomalies lymphatiques. Pour les techniques d'imagerie, certains artefacts sont inévitablement générés pendant le processus d'imagerie. La même situation se produit avec la mammographie car des artefacts sont susceptibles d'être introduits dans la région du muscle pectoral. Par conséquent, les procédures de prétraitement, sont importantes pour les tâches d'analyse potentielles suivantes.[6]

La détection et la classification de la masse mammaire ont une grande valeur pour la détection du cancer du sein car la masse mammaire est l'un des principaux symptômes. Dans les tâches d'analyse d'images médicales, les tissus ciblés, en particulier pour la masse mammaire dans les mammographies, peuvent présenter de fortes similitudes avec les tissus environnants. Dans la région mammaire, les tissus mammaires denses rendent plus difficile la reconnaissance de la masse mammaire. L'inhomogénéité des mammographies peut également nuire aux performances des cadres de détection de la masse mammaire. Un autre facteur clé qui pose des défis à la détection de la masse mammaire est les variations de la masse mammaire elle-même. [6]. Dans les mammographies, les tailles des mammographies sont généralement de plusieurs milliers de pixels par plusieurs milliers de pixels tandis que la masse mammaire ne peut apparaître que dans des zones assez limitées allant de dizaines de pixels à des milliers de pixels. En tenant compte de tous les facteurs ci-dessus, certaines idées des cadres de détection d'objets communs peuvent être empruntées avec des ajustements correspondants. Sur la base de la masse mammaire détectée, le cancer du sein causé par la masse mammaire peut être diagnostiqué comme bénin et malin. Les masses bénignes, qui ne sont pas cancéreuses, peuvent disparaître même sans aucun traitement, mais la détection précoce permet des traitements en temps opportun tels que l'ablation des masses bénignes par chirurgie. Les masses malignes, cependant, sont plus dangereuses car les cellules cancéreuses peuvent se propager dans tout le corps et menacer la vie des patients. De plus, les taux de croissance de ces deux types de masses mammaires sont assez différents car les masses bénignes croissent lentement tandis que les masses malignes croissent beaucoup plus rapidement. Par conséquent, la différenciation correcte entre les masses bénignes et malignes revêt une importance clinique précieuse car des traitements en temps opportun peuvent être appliqués. La biopsie est la méthode la plus efficace mais douloureuse que les patients doivent envisager si aucune alternative possible n'est trouvée. Ainsi, reconnaître les masses mammaires malignes par rapport aux masses bénignes au stade du dépistage par mammographie peut également exempter les patients de la biopsie. Le principal défi pour la différenciation entre les masses bénignes et malignes vient des similitudes de texture, de forme et de taille. Généralement, les masses bénignes ont tendance à avoir des frontières claires tandis que les masses malignes sont plus susceptibles d'avoir des frontières spiculées. Les radiologistes bien formés peuvent remarquer plus de subtilités entre eux et donc établir un diagnostic. Une lecture supplémentaire peut être effectuée si la conclusion n'est pas tout à fait claire. Cependant, il s'agit toujours d'une tâche difficile pour les systèmes d'aide à la décision d'incorporer l'expérience ou les connaissances détaillées sur le sujet dans le diagnostic. Par conséquent, les systèmes d'aide à la décision peuvent être de bons outils pour effectuer un

diagnostic auxiliaire afin de réduire l'intensité de travail des radiologistes, mais ils sont encore loin d'être un remplacement satisfaisant pour les radiologistes. Alors qu'il y a eu de nombreux systèmes d'aide à la décision avant l'ère de l'apprentissage en profondeur, Il est nécessaire d'appliquer des techniques d'apprentissage profond ainsi que des méthodes récentes de vision par ordinateur pour les tâches d'analyse des masses mammaires, en particulier en ce qui concerne le prétraitement, la détection des masses mammaires et leur classification.

2. Dessein et Objectifs

En nous appuyant sur des images de mammographie, nous cherchons à concevoir un système dédié à la détection et à la classification des masses mammaires, en intégrant des algorithmes avancés d'apprentissage profond ainsi que des techniques de vision par ordinateur dans cette thèse. De plus, notre objectif est de contribuer à la création d'une nouvelle base de données de mammographies pour enrichir celles déjà disponibles au public. Par ailleurs, le système proposé et cette nouvelle base de données peuvent être combinés pour réaliser une détection et une classification des masses mammaires de manière intégrée. Nous avons opté pour les images de mammographie en tant que sources d'images en raison de leur large utilisation.

Comme mentionné précédemment, les artefacts dans la vue mammographique et la présence du muscle pectoral dans la vue MLO des mammographies peuvent être perturbants. Ainsi, la création d'un cadre capable de détecter et de segmenter automatiquement les lésions sur les mammographies revêt une importance significative. De plus, la qualité des images mammographiques peut varier en fonction du type de machine utilisée et de l'expérience de l'opérateur, rendant ainsi les masses mammaires plus difficiles à identifier. Par conséquent, il est nécessaire d'implémenter des procédures supplémentaires pour améliorer la performance du système durant la phase de formation. On peut conclure que l'un des principaux défis de l'apprentissage réside dans l'analyse des mammographies en vue MLO, en raison des variations de forme et de taille du muscle pectoral, ainsi que des artefacts et de la qualité d'image. Pour ce qui est de la détection et de la segmentation des masses, les approches peuvent être largement classées en deux catégories : les méthodes traditionnelles et celles fondées sur l'apprentissage profond. Les méthodes traditionnelles s'appuient sur des algorithmes de détection et de segmentation qui exploitent l'intensité des pixels et la texture comme caractéristiques principales pour la segmentation. Cependant, ces méthodes souffrent d'une faible robustesse et d'un manque de performances élevées. En revanche, les méthodes basées sur l'apprentissage profond se sont avérées préférables en raison de leurs performances élevées et de leur robustesse.

Au fil du temps, l'intérêt pour la détection automatique et la classification des masses mammaires a été très important dans le diagnostic du cancer du sein, en raison des exigences pressantes de la pratique clinique. Cependant, malgré les efforts déployés, il n'y a pas eu de solutions parfaites pour la détection des masses mammaires dans les années précédentes, en raison des défis inhérents au domaine. Au lieu de cela, les experts ont largement exploré diverses méthodes visant à obtenir des performances optimales tout en minimisant les interventions manuelles. Contrairement aux premiers systèmes d'aide à la décision qui dépendaient fortement des caractéristiques artisanales, les systèmes d'aide à la décision modernes ont largement bénéficié des avancées en apprentissage profond, ce qui a entraîné une performance et une robustesse supérieures. Les systèmes de détection peuvent être classés en méthodes à un stade, à deux étages et à plusieurs étages, en fonction du nombre d'étapes impliquées. Les méthodes à un et deux étages utilisent généralement des techniques

d'apprentissage profond. Dans les méthodes à un seul stade, les régions d'intérêt (ROIs) sont simultanément déterminées et classées, tandis que dans les méthodes à deux étages, la détermination et la classification des ROIs sont séparées en deux modules distincts. Les méthodes à plusieurs étages, principalement traditionnelles, suivent un pipeline séquentiel composé de prétraitement, de segmentation, d'extraction de caractéristiques et de classification. Cependant, avec l'avancement rapide de l'apprentissage profond, les méthodes basées sur l'apprentissage profond sont progressivement devenues dominantes. Néanmoins, les modèles performants entraînent également des coûts de calcul plus élevés et des exigences matérielles accrues. Dans cette thèse, nous visons à intégrer des approches d'apprentissage profond avec des plateformes récentes pour trouver un équilibre entre la performance et le coût computationnel.

La classification des masses mammaires peut être abordée en utilisant des méthodes traditionnelles d'apprentissage automatique ainsi que des approches basées sur l'apprentissage profond. Alors que les méthodes traditionnelles d'apprentissage automatique reposent fortement sur des caractéristiques extraites manuellement, les méthodes d'apprentissage profond excellent dans l'extraction de caractéristiques de niveau supérieur, ce qui se traduit par une amélioration de la précision de la classification. Dans cette thèse, nous visons à développer un modèle de classification des masses mammaires à haute performance en exploitant les techniques d'apprentissage profond et de l'apprentissage par transfert. Les modèles d'apprentissage profond sont reconnus pour leurs capacités de classification supérieures ; cependant, ils peuvent également servir d'extracteurs efficaces de caractéristiques profondes. Par conséquent, notre focus principal sera d'évaluer la performance des modèles d'apprentissage profond dans l'extraction de caractéristiques. Par la suite, nous sélectionnerons les classifieurs les plus optimaux pour la tâche de classification finale. De plus, nous examinerons l'impact de la taille de l'ensemble des données sur la performance du cadre de classification proposé. Dans cette initiative, notre objectif est de développer un système de classification des masses mammaires qui puisse atteindre une performance similaire à celle des méthodes de pointe.

3. Contributions

Cette thèse fait avancer le domaine en présentant des systèmes automatisés novateurs pour la détection, la segmentation et la classification des images mammographiques. De plus, elle contribue au développement d'une nouvelle base de données pour la mammographie numérique.

Les contributions de cette thèse peuvent être décrites comme suit :

- **Utilisation de Mask R-CNN et du transfert d'apprentissage pour la détection, segmentation et classification du cancer du sein à partir d'images mammographiques :**

Nous exploitons des techniques avancées d'apprentissage profond, notamment Mask R-CNN combiné à l'apprentissage par transfert, pour améliorer la détection, la segmentation et la classification du cancer du sein à partir d'images mammographiques. Mask R-CNN excelle dans la localisation et la segmentation simultanées d'objets avec une grande précision, ce qui le rend idéal pour identifier les anomalies subtiles dans le tissu mammaire. En appliquant l'apprentissage par transfert, nous capitalisons sur des modèles pré-entraînés que nous adaptons et affinons pour notre base de données spécifique. Cette approche non seulement améliore la précision de la détection et de la segmentation des masses, mais aussi affine la classification des masses mammaires en catégories bénignes et malignes. Nos

contributions soulignent l'intégration de technologies de pointe dans le diagnostic du cancer du sein, visant à améliorer le dépistage précoce et les résultats du traitement.

▪ **Contribution : Développement de la Base de Données LAMIS-DMDB pour la Recherche sur le Cancer du Sein**

Notre travail a porté sur le développement de la base de données LAMIS-DMDB, spécifiquement conçue pour la recherche sur le cancer du sein. Cette base de données est méticuleusement structurée en plusieurs catégories essentielles, incluant la classification des anomalies malignes et bénignes, l'évaluation selon le système BI-RADS, et la classification de la densité mammaire. Le processus de collecte et de prétraitement des données, s'étendant de 2017 à 2023, a mobilisé une équipe de chercheurs dédiés, assurant la qualité et la conformité des données pour une utilisation optimale dans les algorithmes d'intelligence artificielle. Les données ont été rigoureusement nettoyées, normalisées et standardisées pour garantir leur cohérence et leur fiabilité. Des expériences approfondies ont été menées pour évaluer dans quelle mesure la base de données répond aux exigences des techniques d'apprentissage automatique et profond, notamment les CNN et l'apprentissage par transfert, en termes de précision et de robustesse. Cette contribution a abouti à la création d'une ressource précieuse pour la communauté de recherche, facilitant l'accès à une vaste gamme de données patient et offrant une vue complète des diagnostics et des historiques de traitement liés au cancer du sein.

4. Plan de lecture de la thèse

Le reste de cette thèse est structurée en quatre chapitres principaux, chacun contribuant à approfondir la compréhension et l'avancement dans le domaine du diagnostic du cancer du sein. Ce premier chapitre se concentre sur l'exploration des concepts médicaux essentiels liés au cancer du sein. Une attention particulière est portée à l'imagerie médicale, en particulier la mammographie, qui constitue une méthode cruciale pour le dépistage précoce et le diagnostic de cette maladie. Une analyse détaillée des bases de données publiques de mammographies est réalisée, accompagnée d'une comparaison entre ces différentes ressources, mettant en lumière leurs avantages et limitations.

Le deuxième chapitre examine l'état actuel des systèmes de diagnostic assisté par ordinateur appliqués au cancer du sein. Il offre un panorama complet des techniques avancées utilisées pour la détection, la segmentation et la classification des masses mammaires à partir d'images médicales. En explorant les approches innovantes et les technologies émergentes, ce chapitre vise à définir les fondements théoriques et pratiques des systèmes de diagnostic assisté par ordinateur dans ce domaine spécifique.

Le troisième chapitre se concentre sur l'implémentation pratique du système proposé pour la détection, la segmentation et la classification des masses mammaires. Il détaille les méthodologies et les algorithmes utilisés, ainsi que les différentes expérimentations menées pour évaluer les performances et l'efficacité du système. Cette section inclut une analyse approfondie des résultats obtenus, mettant en évidence les défis rencontrés et les solutions proposées pour améliorer la précision et la robustesse du système.

Le quatrième et dernier chapitre présente la base de données LAMIS-DMDB spécifiquement développée pour la recherche sur le cancer du sein. Il décrit en détail la structure de la base de données, les méthodes de collecte et de prétraitement des données, ainsi que les expériences menées pour enrichir cette ressource. En outre, ce chapitre explore l'intégration du système développé avec la base de données LAMIS-DMDB, facilitant ainsi une annotation

semi-automatique des images mammographiques et contribuant à accélérer le processus d'analyse et de diagnostic clinique.

Cette structure de thèse est conçue pour fournir une compréhension approfondie du contexte médical du cancer du sein, des avancées technologiques dans les systèmes de diagnostic assisté par ordinateur, de la mise en œuvre pratique d'un système innovant, et de l'utilisation stratégique d'une base de données spécialisée pour soutenir la recherche et le développement futurs dans ce domaine critique de la médecine.

CHAPITRE I :
Contexte Médical du Cancer
du sein



Chapitre I : Contexte médical

Du cancer sein

1. Introduction au Cancer du Sein

L'éveil à la problématique du cancer du sein nécessite une compréhension des distinctions entre la physiologie normale du sein et une anomalie qui pourrait se révéler bénigne, précancéreuse ou maligne. Les organisations nationales de la santé conseillent que les femmes soient bien informées de leur anatomie mammaire et qu'elles soient en mesure d'échanger avec leur médecin pour signaler toute anomalie préoccupante. L'amélioration de la compréhension de la physiologie normale pourrait contribuer à prévenir ou à diminuer la négligence des femmes en ce qui concerne l'auto-examen et la sollicitation d'une aide médicale pour un examen clinique du sein en temps opportun. En outre, une compréhension approfondie de l'anatomie mammaire pourrait faciliter une communication plus efficace entre les experts en technologie et les professionnels de la santé, tout en favorisant l'élaboration de protocoles de dépistage et de diagnostic plus efficaces[7].

1.1. Généralité sur le Tissu Normale du Sein :

Les différences interindividuelles normales dans la distribution du tissu mammaire sont influencées par le patrimoine génétique et le mode de vie[8]. La distribution hétérogène des tissus mammaires ne permet pas d'établir des mesures standard. Selon les Centres pour le contrôle et la prévention des maladies, 10 % des femmes possèdent des seins gras, 40 % des seins avec quelques zones de tissu dense, 40 % des seins hétérogènes et 10 % ont des seins extrêmement denses[9]. La densité mammaire se classe en : première catégorie : principalement composée de tissu adipeux (faible densité), deuxième catégorie : tissu fibroglandulaire dispersé (densité moyenne), troisième catégorie : tissu hétérogène (haute densité) et quatrième et dernière catégorie : tissu extrêmement dense (très haute densité). Le tissu mammaire dense est reconnu comme un facteur de risque biologique indépendant pour l'apparition du cancer du sein. De surcroît, il complique l'évaluation du cancer du sein par les radiologues et les médecins, en entravant la détection des tumeurs à un stade précoce en raison de son effet d'occultation [9, 10].

Il est crucial de souligner que les seins subissent une évolution constante, influencée par divers facteurs tels que les changements mode de vie, hormonaux, la génétique, et la densité mammaire. Une connaissance approfondie de l'anatomie et de la physiologie du tissu mammaire normal est essentielle pour comprendre le processus de développement du cancer du sein. Cette compréhension pourrait également améliorer la détection précoce des lésions potentiellement pathologiques. La sensibilisation au cancer du sein est un outil précieux pour atténuer la négligence des femmes envers leur santé. Elle peut également encourager les patientes à consulter un professionnel de la santé et à établir une communication efficace avec les médecins.

1.2. Anatomie du Sein :

Le sein est un organe complexe constitué de tissu adipeux, de tissu glandulaire et de structures de soutien, telles que les nerfs, les artères, les veines et le tissu conjonctif. Tout au long de la vie, il connaît d'importantes transformations dues à divers processus, notamment la mammogénèse, la lactogénèse et l'involution.[11]. Comprendre son développement, son apport sanguin et son drainage lymphatique est crucial dans la gestion clinique des maladies du sein[12]. En plus, le sein adulte est un organe fibroadipose qui s'étend de la deuxième à la sixième côte et du sternum à la ligne axillaire antérieure, avec un mamelon saillant et une aréole discoïdale[13].

Anatomiquement, le sein est positionné au-dessus des muscles pectoraux et est soutenu par les ligaments suspenseurs du sein (ligaments de Cooper). Il est constitué d'un réseau complexe d'artères, de veines et de vaisseaux lymphatiques qui assurent le transport du sang, des nutriments et des messagers chimiques, ainsi que l'évacuation des déchets[11, 12]. L'approvisionnement sanguin du sein est assuré par les artères mammaires internes et les artères thoraciques latérales, en complément des petits vaisseaux sanguins. Le drainage veineux du sein s'effectue par l'intermédiaire de veines présentes dans les zones thoracique, axillaire et céphalique. Le drainage lymphatique du sein comprend les ganglions axillaires et les ganglions mammaires internes. La lymphe est principalement drainée des ganglions médiaux et latéraux vers le ganglion axillaire. La couche de graisse enveloppe le tissu glandulaire, qui est organisé en 15 à 20 sections appelées lobes de tissu adipeux. À l'intérieur de chaque lobe se trouvent des structures plus petites appelées lobules, qui contiennent entre 10 et 100 alvéoles (d'un diamètre de 0,12 mm)[11, 14, 15]. Ces glandes atteignent leur pleine maturité pendant la grossesse et le cycle de lactation, lorsque l'organe est préparé pour synthétiser et sécréter le lait, un processus qui nécessite environ 25 % de l'énergie maternelle quotidienne [11, 14]

- 1 Cage thoracique
- 2 Muscle pectoral
- 3 Lobules
- 4 Lobes
- 5 Surface du mamelon
- 6 Aréole
- 7 Canal galactophore
- 8 Tissu adipeux
- 9 Tissu conjonctif

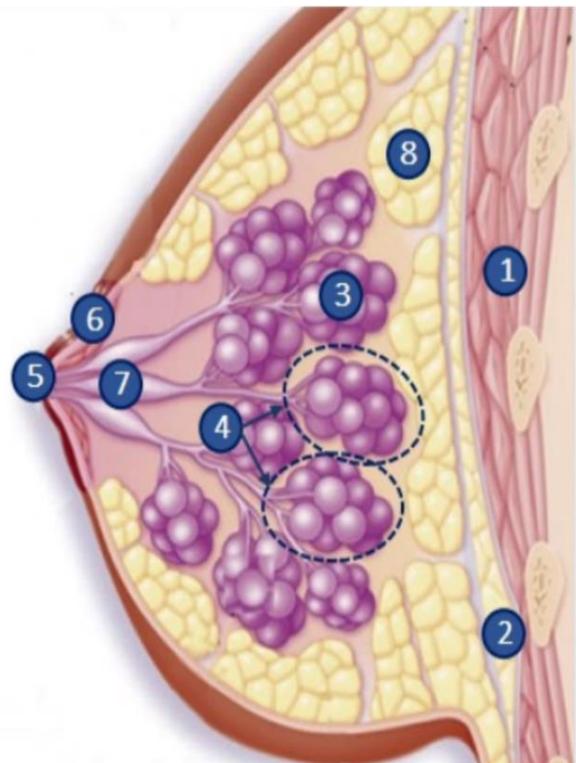


Figure I. 1: L'anatomie du sein [16]

1.3. Comprendre le Cancer du Sein :

Le cancer du sein est une affection maligne qui se manifeste lorsque des cellules anormales dans le tissu mammaire se multiplient de manière incontrôlée [17]. Cette maladie comprend plusieurs types, dont les principaux sites d'origine sont les lobules, les canaux et le tissu conjonctif du sein. Les lobules sont chargés de la production de lait, tandis que les canaux agissent comme des conduits pour acheminer le lait vers le mamelon. Le tissu conjonctif assure un soutien structurel et une cohésion au sein. En général, les tumeurs cancéreuses ont leur origine dans les lobules ou les canaux, donnant lieu respectivement à un cancer in situ lobulaire ou canalaire, et peuvent potentiellement métastaser vers d'autres organes via la circulation sanguine. Parmi les types de cancer du sein les plus courants, on distingue le carcinome canalaire infiltrant (invasif), qui se caractérise par la propagation de cellules cancéreuses en dehors des canaux, ainsi que le carcinome lobulaire infiltrant (invasif), où les cellules cancéreuses se forment en dehors des lobules. Des variantes moins courantes comprennent également le cancer médullaire, mucineux et inflammatoire du sein [16, 18, 19]. Les symptômes du cancer du sein peuvent différer d'une personne à l'autre, et certaines peuvent ne présenter aucun symptôme du tout. Cependant, des signes indicateurs peuvent inclure la présence d'une nouvelle bosse dans le sein ou sous le bras, l'épaississement ou le gonflement du tissu mammaire, une irritation cutanée ou des plis, des rougeurs ou des desquamations autour du mamelon, le renflement vers l'intérieur du mamelon, des douleurs mamelonnaires, des écoulements non liés à l'allaitement (y compris du sang), des changements dans la taille ou la forme du sein ainsi que des douleurs localisées au niveau mammaire. Ces symptômes nécessitent une évaluation médicale rapide pour un diagnostic précis et une prise en charge appropriée [18, 20].

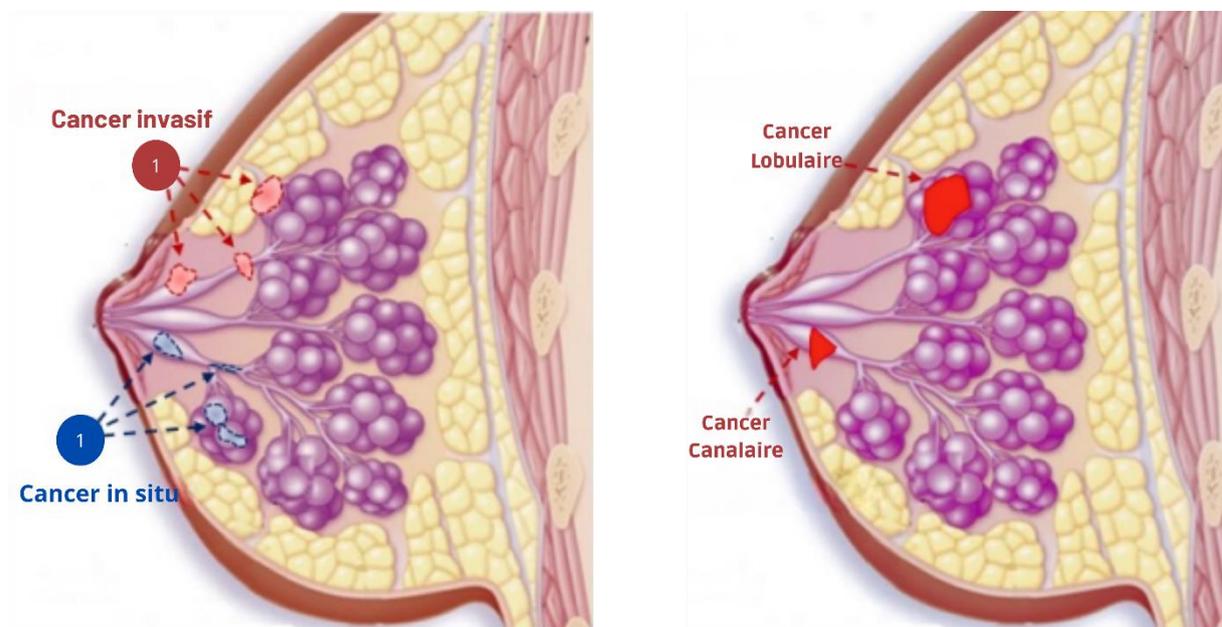


Figure 1. 2: Représentation graphique des stades du cancer ;

La figure illustre graphiquement les différents stades du cancer, classés selon la localisation et l'étendue de la croissance tumorale, ainsi que la propagation éventuelle à des ganglions lymphatiques adjacents ou à d'autres régions du corps. La représentation graphique comprend quatre catégories : Cancer Lobulaire invasif, Cancer Lobulaire in-situ, Cancer Canalaire invasif, Cancer Canalaire in-situ.

1.4. Les Facteurs De Risques Du Cancer Du Sein :

Le cancer du sein est une pathologie complexe qui affecte des millions d'individus à travers le monde, se manifeste à travers une interaction complexe de facteurs génétiques, environnementaux et liés au mode de vie.

Parmi les principaux facteurs de risque liés au cancer du sein, on peut identifier [4, 18, 19] :

- ❖ Le genre : les femmes sont principalement touchées par cette maladie, bien que les hommes puissent également en être atteints, mais de manière nettement moins fréquente.
- ❖ Le vieillissement : le risque de développer un cancer du sein s'accroît avec l'âge, affichant une incidence plus élevée chez les femmes de plus de 55 ans par rapport à celles qui sont plus jeunes.
- ❖ Les facteurs héréditaires : environ 10 % des cas de cancer du sein sont attribuables à des mutations génétiques héréditaires.
- ❖ Les antécédents familiaux : une histoire familiale de cancer du sein augmente le risque de développer la maladie.
- ❖ L'ethnicité et la race : des variations de risque sont observées entre différentes populations, avec une incidence plus élevée chez les femmes caucasiennes, bien que cet écart se réduise progressivement.
- ❖ La taille : les femmes de grande taille ont un risque accru de cancer du sein, possiblement en raison d'influences sur la croissance précoce et les facteurs hormonaux.
- ❖ La densité mammaire : une densité mammaire élevée peut rendre la détection des tumeurs plus difficile et est associée à un risque accru de cancer du sein.
- ❖ Certaines conditions bénignes du sein : certaines conditions non cancéreuses du sein peuvent augmenter le risque de développer un cancer du sein.
- ❖ Le début précoce des menstruations et le début tardif de la ménopause : ces facteurs sont associés à un risque légèrement accru de cancer du sein en raison d'une exposition prolongée aux hormones féminines.
- ❖ L'exposition à des radiations thoraciques : une exposition à des radiations thoraciques, notamment pendant l'adolescence, peut augmenter considérablement le risque de cancer du sein.
- ❖ L'exposition au diéthylstilbestrol (DES) : les femmes exposées au DES pendant la grossesse, ainsi que leurs enfants, peuvent présenter un risque accru de cancer du sein.

LES FACTEURS DE RISQUE INCONTRÔLABLES



Figure 1. 3: Les facteurs de risque pour le cancer du sein

L'illustration graphique présente différents facteurs de risque pour le cancer du sein, considérés comme incontrôlables. Les facteurs de risque contrôlables comprennent l'obésité, le manque d'exercice physique, la consommation d'alcool. Les facteurs de risque qui ne peuvent pas être contrôlés incluent les mutations génétiques, les antécédents familiaux de cancer cervical.

1.5.Méthodes de dépistage et de diagnostic du cancer du sein :

Il est essentiel de détecter précocement le cancer du sein afin d'assurer un traitement efficace et un pronostic amélioré. Les techniques de détection et de diagnostic sont cruciales pour repérer les lésions suspectes et confirmer la présence d'un cancer du sein. Différentes méthodes sont employées pour détecter et diagnostiquer le cancer du sein, chacune ayant ses propres bénéfices et limites.

Parmi ces méthodes de dépistage et de diagnostic utilisées dans la pratique clinique [21–23] :

1. Auto-examen des seins (AES) :

L'auto-examen des seins consiste à effectuer un examen méticuleux de ses seins afin de repérer toute masse, tout changement de texture ou toute anomalie. Bien que l'AES soit simple et économique, Il est possible qu'il ne soit pas aussi précis que d'autres méthodes de dépistage et dépend grandement de la sensibilisation et de la conformité du patient.

2. Examen clinique des seins (ECS) :

Les seins sont examinés par un professionnel de la santé, habituellement un médecin ou une infirmière spécialisée, qui examine manuellement les seins à la recherche de toute masse palpable ou irrégularité. L'ECS est une composante essentielle des examens réguliers et peut contribuer à repérer des anomalies qui requièrent une investigation approfondie.

3. Mammographie :

La mammographie est utilisée pour détecter le cancer du sein chez les femmes qui ne présentent pas de symptômes. Elle consiste à prendre des images radiographiques du tissu mammaire pour détecter toute masse ou calcification suspecte. Bien que la mammographie ait démontré son efficacité dans la réduction de la mortalité par cancer du sein, elle peut présenter des limites chez les femmes ayant un tissu mammaire dense et peut entraîner des résultats faussement positifs ou négatifs. Par conséquent, une expertise significative est requise pour l'interprétation des images mammographiques. Dans les prochaines parties de ce chapitre, nous examinerons en profondeur la technique de mammographie.

4. Échographie mammaire :

L'échographie mammaire, ou sonographie, utilise des ondes sonores pour produire des images du tissu mammaire. Elle est souvent utilisée comme modalité d'imagerie complémentaire pour évaluer les anomalies mammaires détectées à la mammographie ou lors de l'examen clinique. L'échographie est particulièrement utile pour distinguer les lésions kystiques des lésions solides et pour guider les biopsies à l'aiguille.

5. Imagerie par résonance magnétique (IRM) :

En utilisant des champs magnétiques et des ondes radio, l'IRM mammaire permet de produire des images précises du tissu mammaire. Elle est principalement utilisée chez les personnes à haut risque ou pour une évaluation approfondie des résultats équivoques à la mammographie ou à l'échographie. L'IRM est très sensible mais moins spécifique que la mammographie, et son utilisation est souvent réservée à des scénarios cliniques spécifiques.

6. Biopsie :

La biopsie est la procédure diagnostique définitive pour le cancer du sein, impliquant le prélèvement d'un échantillon de tissu de la lésion suspecte pour examen histopathologique. En fonction des caractéristiques de la lésion et du contexte clinique, différentes méthodes de biopsie, telles que la biopsie à l'aiguille centrale, la biopsie assistée par aspiration et la biopsie chirurgicale, peuvent être employées.

7. Tests moléculaires et génétiques :

Les analyses moléculaires et génétiques du tissu cancéreux du sein peuvent être utiles pour déterminer le sous-type de tumeur, le statut des récepteurs hormonaux, l'expression de HER2 et la présence de mutations génétiques spécifiques (comme BRCA1/2). Ces examens sont essentiels pour prendre des décisions thérapeutiques et prédire la réponse aux thérapies spécifiques.

On utilise une combinaison de techniques de dépistage et de diagnostic afin de repérer et de caractériser de manière efficace les lésions du cancer du sein. La sélection de modalités appropriées dépend de facteurs tels que l'âge du patient, le profil de risque, la densité mammaire et la présentation clinique, dans le but ultime d'obtenir un diagnostic rapide et des résultats thérapeutiques optimaux. Dans le reste de ce chapitre on détaille la mammographie

1.6. La Prévention du Cancer du Sein :

La prévention du cancer du sein est une démarche complexe qui comprend différentes approches pour diminuer le risque de contracter cette maladie. Parmi ces stratégies, maintenir un poids corporel sain est crucial, car un excès de poids, surtout après la ménopause, est lié à une augmentation du risque de cancer du sein. Il est donc recommandé de maintenir un équilibre entre l'apport alimentaire et l'activité physique tout au long de la vie. En parlant d'activité physique, de nombreuses études ont montré qu'une activité physique régulière, allant de modérée à intense, est liée à un risque plus faible de cancer du sein. De plus, il est également connu que la consommation d'alcool est un facteur de risque pour le cancer du sein, même à des niveaux minimes. En outre, l'allaitement maternel pendant plusieurs mois peut offrir une protection supplémentaire contre le cancer du sein. Les femmes qui allaitent ont la possibilité de diminuer leur risque de contracter la maladie. La consultation génétique peut être bénéfique pour les femmes à risque génétique élevé, telles que celles ayant des antécédents familiaux de cancer du sein ou portant des mutations génétiques telles que BRCA1 ou BRCA2. Cela peut permettre d'évaluer le risque individuel et d'explorer les options de dépistage et de prévention. En cas de risque accru, un suivi médical régulier, comprenant des visites fréquentes chez le médecin, des dépistages précoces et éventuellement des IRM mammaires, peut être recommandé. Dans certaines situations, il est possible de prescrire des médicaments afin de diminuer le risque de cancer du sein chez les femmes à risque élevé. Cependant, ces médicaments peuvent avoir des effets secondaires et doivent être discutés avec un professionnel de la santé. Enfin, pour une petite fraction de femmes présentant un risque extrêmement élevé, comme celles ayant une mutation génétique BRCA, la chirurgie préventive pour retirer les seins (mastectomie) ou les ovaires (ophorectomie) peut être considérée comme une option. Cependant, cette décision doit être soigneusement pesée en tenant compte des avantages et des inconvénients, et discutée en profondeur avec un médecin spécialisé[4, 7, 18].

2. Imagerie Médical

L'imagerie médicale est une discipline essentielle dans le domaine de la santé, permettant aux professionnels de visualiser l'intérieur du corps humain pour diagnostiquer, surveiller et traiter les maladies. Elle englobe une variété de techniques, y compris la radiographie, l'échographie, l'IRM, et bien sûr, la mammographie.

2.1.Mammographie Numérique (Digital Mammography) :

Les tests et procédures de dépistage sont des outils essentiels pour repérer les maladies chez les individus asymptomatiques. L'objectif principal du dépistage du cancer du sein est d'identifier la maladie à un stade précoce, avant même que les symptômes ne se manifestent. La détection précoce implique l'identification et le traitement d'une affection avant l'apparition de symptômes cliniquement significatifs. Parmi les méthodes utilisées pour ce dépistage précoce du cancer du sein, la mammographie numérique occupe une place centrale. Cette technique consiste à utiliser des rayons X pour obtenir des images du tissu mammaire, offrant ainsi le moyen le plus efficace de dépister précocement le cancer du sein, une pratique très répandue et acceptée dans le domaine de la santé.

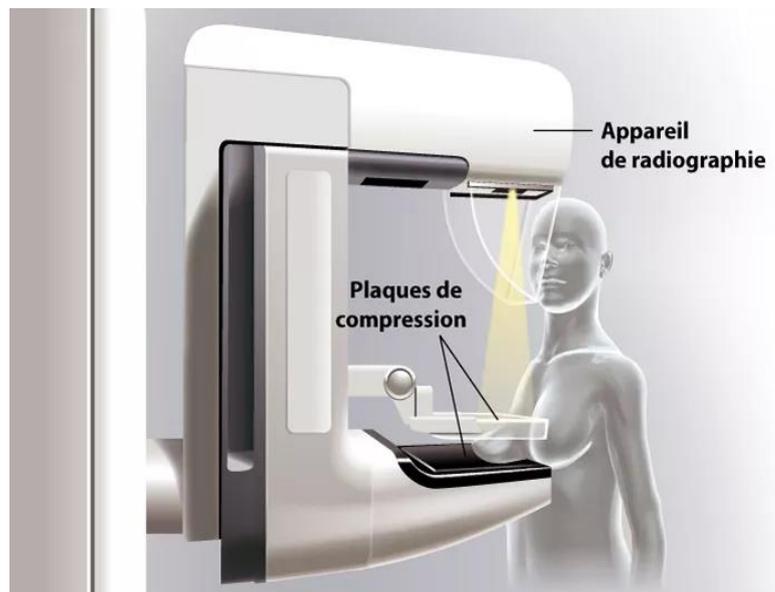


Figure I. 4: L'utilisation de la machine de mammographie et la prise d'images mammaires[24].

Au cours de mammographie, les images sont capturées à partir de plusieurs angles de vue afin d'obtenir davantage d'informations avant la détection. Les deux vues mammographiques couramment utilisées sont MLO et le CC. Dans la vue CC, le sein est comprimé entre deux palettes, révélant les tissus glandulaires et adipeux. La mammographie est réalisée horizontalement avec un angle de bras de 0° . La perspective MLO, placée à un angle de bras de 45° , comprime le sein de manière parallèle entre les palettes. Cet angle permet une imagerie plus large du tissu mammaire que la vue CC. Dans cette vue, les muscles pectoraux sont également visibles dans la mammographie. Les différents éléments de la mammographie numérique tels qu'observés dans le sein sont présentés dans la Figure I. 5.

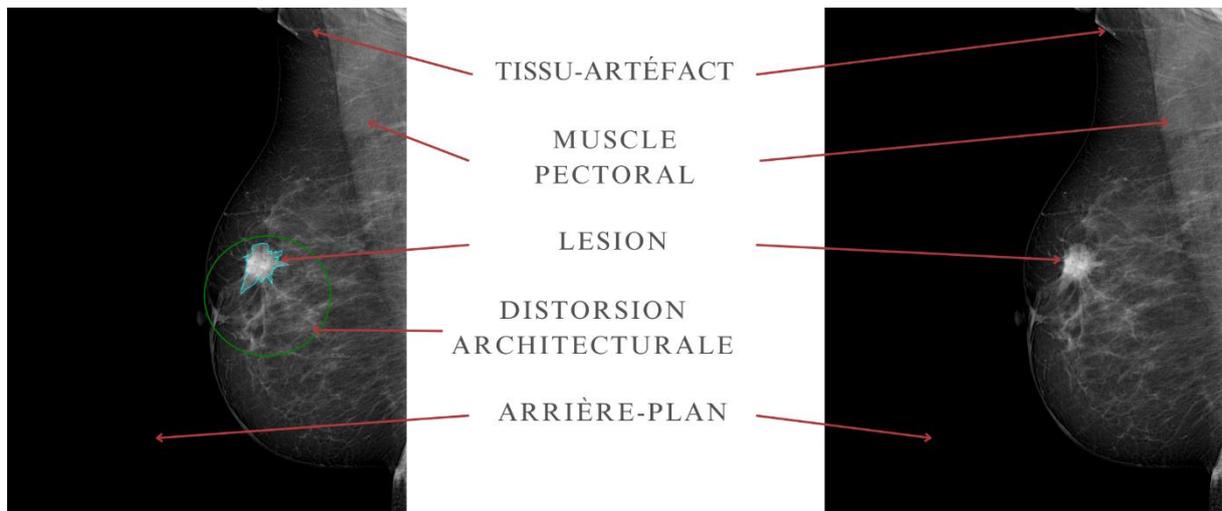


Figure 1. 5: Les divers composants de l'imagerie numérique de mammographie de l'ensemble de données LAMISDMDB[25]

Les professionnels de l'imagerie médicale préfèrent la mammographie numérique à d'autres modalités d'imagerie car elle permet de réaliser des images plus rapidement, bénéficie d'une résolution supérieure, d'un rapport signal sur bruit élevé, et elle peut également détecter de petites masses et des calcifications. L'exactitude diagnostique s'est considérablement améliorée grâce aux efforts de la communauté scientifique pour évaluer les mammographies, ce qui a contribué de manière significative à l'amélioration du taux de survie en détectant la maladie.

2.2. Interprétation des mammographies

Une fois l'examen de mammographie achevé, un professionnel expert dans le domaine, généralement un radiologue, procède à l'examen des images numériques obtenues afin de détecter toute altération ou anomalie. Sur la base de cette analyse, le radiologue évalue le risque et prend des décisions cliniques, puis prescrit des traitements appropriés. Afin de garantir une terminologie uniforme et de faciliter la communication entre les praticiens, plusieurs systèmes de classification ont été développés. Parmi eux, le système de reporting et de données du Breast Imaging (BI-RADS) est le plus fréquemment employé[26].

2.2.1. Classification BI-RADS

Le système BI-RADS a été créé en 1993 par l'American College of Radiology (ACR) afin de standardiser les rapports mammographiques, d'améliorer la communication entre les professionnels, de réduire les malentendus liés aux résultats mammographiques, de soutenir la recherche, et de simplifier le suivi des résultats. Tableau 1 présente les classifications BI-RADS et les recommandations des experts radiologues, avec des catégories allant de l'évaluation incomplète (catégorie 0) aux évaluations complètes (catégories 1-6)[26]. Ces classifications guident les recommandations pour des examens d'imagerie supplémentaires, la mammographie de routine, le suivi à court terme ou la biopsie, reflétant le soupçon de malignité du radiologue. La collaboration entre les radiologues, les médecins et les patients est facilitée grâce au lexique BI-RADS, qui soutient les efforts d'amélioration de la qualité et de recherche[26].

Tableau I. 1: Le tableau représente le système de classification BI-RADS établi par ACR. Chaque catégorie correspond à un niveau de suspicion de malignité, associé à des recommandations et une probabilité de cancer.[26]

Catégorie	Définition	Recommandations	Probabilité de cancer
0	Incomplet	Besoin de réaliser des examens d'imagerie complémentaires	N/A
1	Négatif	Suivi de dépistage.	Essentiellement 0%
2	Benin	Suivi de dépistage.	Essentiellement 0%
3	Probablement Benin	Surveillance rapprochée (dans 6 mois)	$\leq 2\%$
4	A Anomalie maligne suspecte faible	Réaliser une biopsie, de préférence une biopsie par aiguille (Diagnostic Tissulaire)	$(\geq 2\% \text{ à } 10\%)$
	B Anomalie maligne suspecte modérée		$(\geq 10\% \text{ à } 50\%)$
	C Anomalie maligne suspecte élevée		$(\geq 50\% \text{ à } 95\%)$
5	Fortement évocateur d'une malignité	Biopsie et traitement, si nécessaire.	$\geq 95\%$
6	Malignité connue prouvée par biopsie, traitement en cours	S'assurer que le traitement est complété	N/A

2.2.2. La Densité mammaire

L'analyse de la densité mammaire, qui correspond à la proportion de tissus fibroglandulaires par rapport aux tissus adipeux, est essentielle pour interpréter les mammographies et détecter le cancer du sein. Une densité mammaire élevée, caractérisée par une proportion accrue de tissu fibroglandulaire, est associée à un risque accru de cancer du sein. L'augmentation de la densité mammaire, qui se manifeste par une augmentation de la proportion de tissu fibroglandulaire, est liée à un risque plus élevé de cancer du sein. À l'inverse, une densité plus faible indique une proportion plus élevée de tissu adipeux. La densité mammaire évolue au cours du temps et est affectée par divers facteurs tels que, la grossesse, l'âge, et le traitement hormonal substitutif [10, 27]. En mammographie, les tissus mammaires denses apparaissent blancs, ce qui peut rendre la détection du cancer du sein plus difficile, Alors que les adipocytes sont plus foncés, ce qui facilite la détection des anomalies. Étant donné que les femmes ayant une densité mammaire élevée peuvent être plus susceptibles de recevoir un diagnostic tardif de cancer en raison de la possibilité de faux négatifs. Divers systèmes d'évaluation de risques ont été développés pour

estimer la probabilité de développement du cancer du sein, avec la densité mammaire comme indicateur important. La densité mammaire est divisée en quatre catégories selon le pourcentage de tissu fibroglandulaire, tel que défini par ACR, La Figure 6 illustre ces quatre catégories de densité mammaire[16] :

- **Graisseux homogène (ACR1)** : Cette catégorie se caractérise par un sein entièrement composé de tissu adipeux, où le pourcentage de tissu fibroglandulaire est inférieur à 25%. La présence de graisse rend l'interprétation des mammographies numériques relativement facile.
- **Graisseux hétérogène (ACR2)** : Dans cette catégorie, la peau du sein est transparente avec des opacités éparpillées. Le taux de fibroglandulaire oscille entre 25 % et 50 %.
- **Hétérogène Dense (ACR3)** : Les seins de cette catégorie présentent une densité et une diversité, avec une proportion de tissu fibroglandulaire allant de 50 % à 75 % de la glande mammaire. Les mammographies numériques peuvent être difficiles à interpréter en raison de cette densité qui peut dissimuler les petites masses.
- **Dense homogène (ACR4)** : Les seins de cette catégorie sont très denses et homogènes, avec un taux de tissu fibroglandulaire supérieur à 75%. Une densité aussi élevée peut non seulement compliquer l'interprétation des mammographies numériques mais également réduire leur sensibilité.

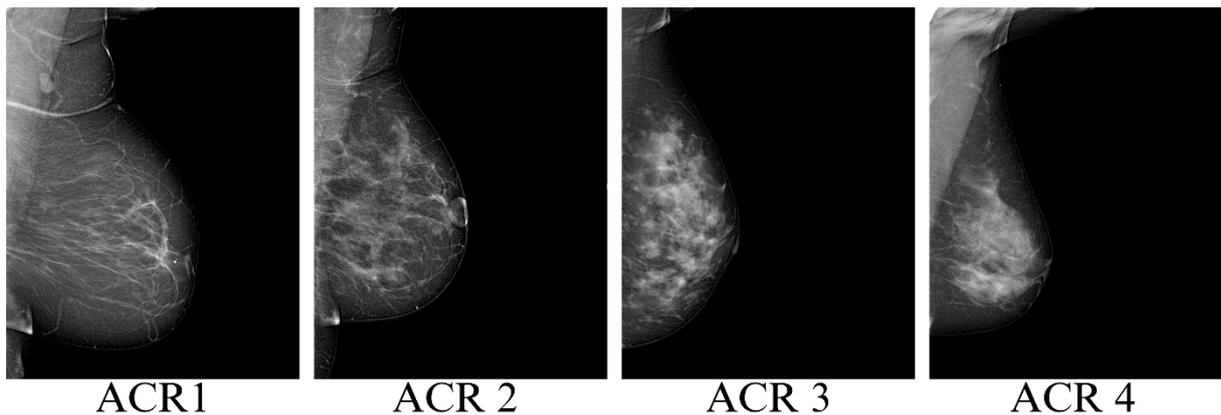


Figure 1. 6 : Les différentes classes de densité utilisées pour la mammographie numérique. Les images dans la figure appartiennent à l'ensemble de données LAMISDMDB.

2.2.3. Anomalies Identifiable par la Mammographie

La mammographie numérique joue un rôle essentiel dans la détection précoce du cancer du sein en permettant d'identifier d'éventuelles anomalies potentiellement malignes. En effet, cette modalité d'imagerie offre une visualisation détaillée du tissu mammaire, permettant aux professionnels de la santé d'observer les structures internes avec une précision élevée. La mammographie peut être accompagnée d'anomalies de taille, de forme et de densité, telles que les masses, les calcifications, les distorsions architecturales et les asymétries. Ils requièrent une expertise radiologique approfondie pour être interprétés[16, 28, 29].

L'asymétrie mammaire se caractérise par une disparité de densité et de structures anatomiques entre les images mammographiques droite et gauche, tant en vue MLO qu'en vue CC. Cette asymétrie, souvent associée à la présence d'une lésion cancéreuse, est identifiable par

des densités inégales observées sur les deux vues[30]. La Figure I. 7 présente une anomalie de type asymétrie mammaire détectable à partir de la mammographie.

Les distorsions architecturales, quant à elles, correspondent à une altération de la structure normale du tissu mammaire. Elles se caractérisent généralement par des projections en forme de spicules irradiant à partir d'un point central, ainsi que par une rétraction ou une distorsion des contours du sein, lorsqu'elles sont situées à proximité. La Figure 8 présente un exemple d'anomalie de type distorsions architecturales détectable à partir de la mammographie.

Les calcifications sont de minuscules particules de calcium présentant différents motifs. Il est difficile d'évaluer la malignité des calcifications en raison de leur aspect flou et de la difficulté à les différencier de leur environnement, surtout dans les seins denses. Les calcifications sont généralement classées en fonction de leur localisation, de leur distribution, de leur densité et de leur forme. Les calcifications linéaires et segmentaires sont de nature maligne, tandis que les calcifications diffuses et régionales sont considérées comme bénignes, comme peut le voir sur la Figure 10. La Figure 9 illustre une anomalie de type calcifications détectable à partir de la mammographie.[29, 31]

Enfin, les masses, des lésions occupant un espace dans le sein, sont visibles sur les deux incidences de la mammographie. Leur caractérisation repose sur des critères tels que la forme, la densité et le contour, permettant d'évaluer leur nature et leur potentiel de malignité. La Figure 11 montre une anomalie de type masse détectable par la mammographie[29, 32]. Comme on peut le voir sur la Figure. 12, les masses rondes, ovales et lobulées sont principalement bénignes, tandis que les types de masses malignes les plus courants sont nodulaires et stellaires[29].

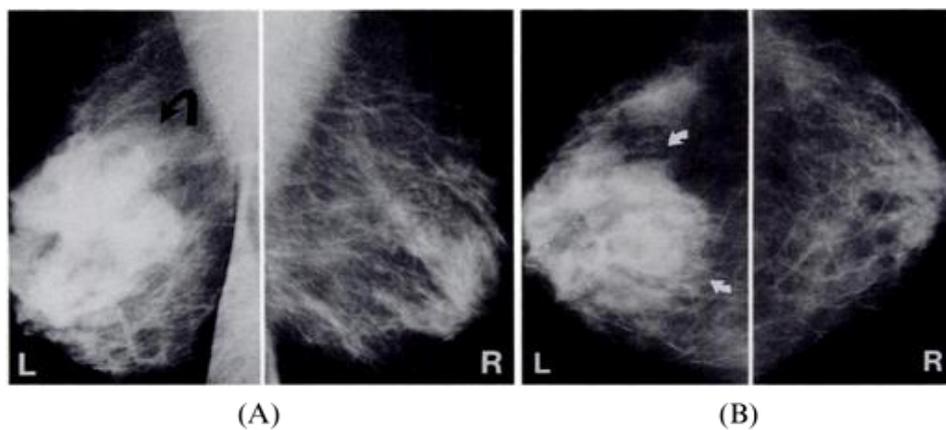


Figure I. 7: Un volume asymétrique bénin du tissu mammaire (flèches) est visible dans la partie supérieure du sein gauche. (A): MLO, (B): CC; R: droite, L: gauche.[30]

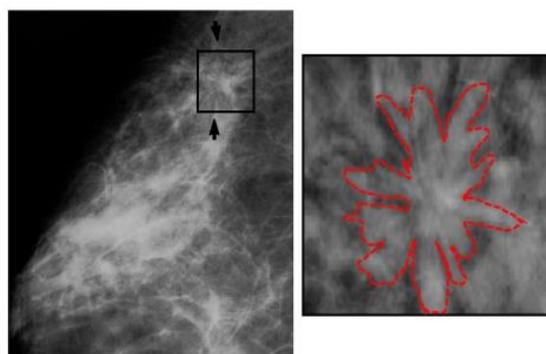


Figure I. 8: Illustration d'une distorsion architecturale visible sur une image mammographique avec un agrandissement.[16]

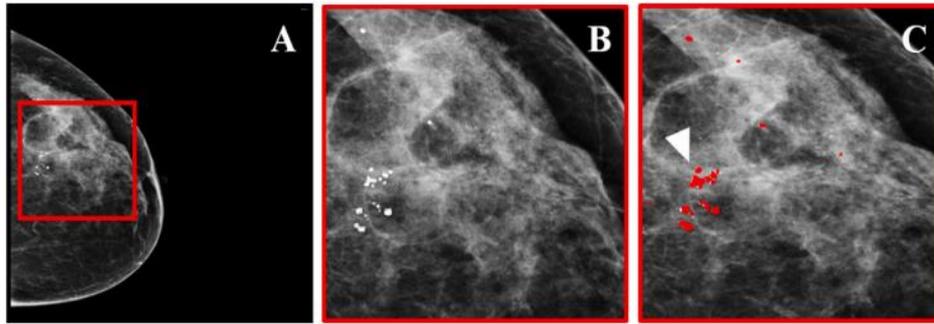


Figure I. 9: (A) Mammographie d'une femme présentant des microcalcifications (MC) et un amas de microcalcifications (MCC). (B) Région agrandie marquée par le carré rouge dans A, montrant des MC et un MCC. (C) La région en B avec un marquage précis des emplacements des MC et du MCC.[28]

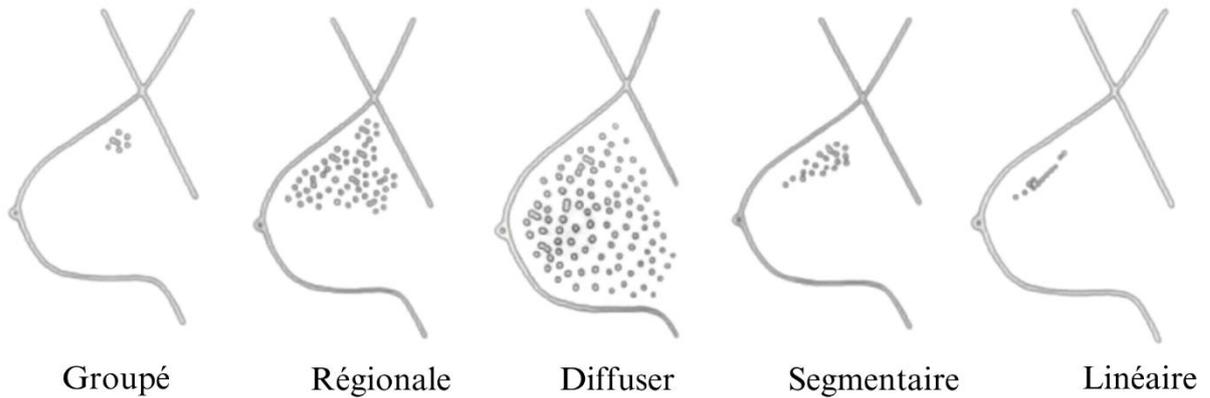


Figure I. 10: La figure présente la typologie des calcifications selon leur répartition.[31]

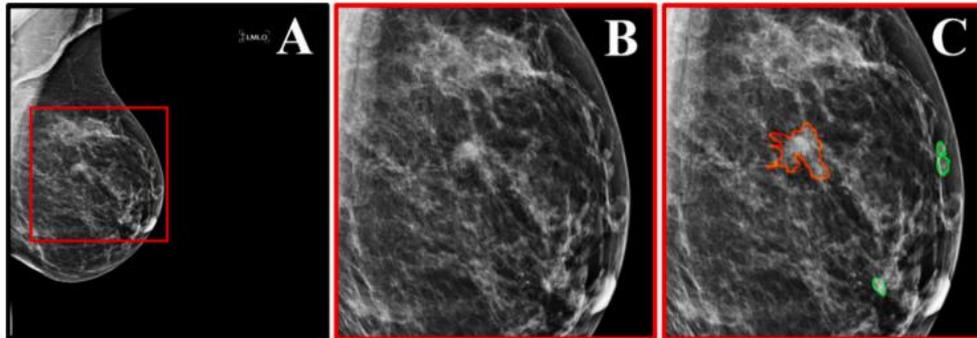


Figure I. 11: (A) Mammographie d'une femme avec des masses bénignes et suspectes. (B) Région agrandie marquée par le carré rouge dans A, montrant les masses. (C) La région en B avec un marquage précis des emplacements des masses (vert pour bénin, rouge pour suspect).[28]

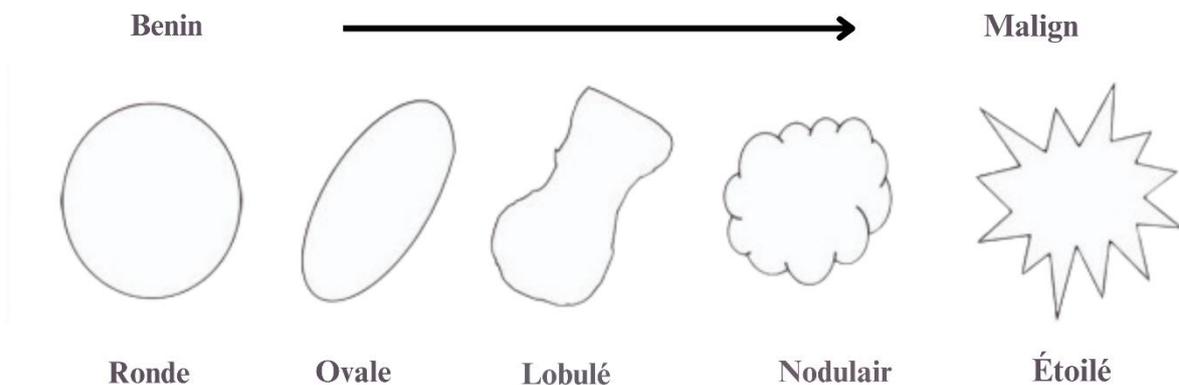


Figure I. 12: La figure illustre comment les masses sont caractérisées en fonction de leur forme et de leurs limites[29]

2.2.4. Les défis des radiologues dans l'interprétation des mammographies

Dans l'interprétation des mammographies, les radiologues font face à de nombreux défis qui impactent la précision et l'efficacité de la détection du cancer du sein. Dans un premier temps, la complexité intrinsèque des images mammographiques, souvent marquée par des différences subtiles de densité tissulaire et des structures superposées, représente un défi majeur. Cette complexité peut conduire au masquage de lésions ou à l'interprétation erronée de résultats bénins comme potentiellement malins, affectant ainsi la précision diagnostique. De plus, les radiologues doivent composer avec la nature subjective de l'interprétation des mammographies, car l'expertise individuelle et le niveau d'expérience peuvent influencer les décisions diagnostiques. De plus, la prévalence des faux positifs et des faux négatifs complique davantage le processus d'interprétation, nécessitant une réflexion minutieuse pour minimiser le risque de surdiagnostic et de diagnostics manqués. En outre, des facteurs tels que les variations de qualité d'image, la fatigue et les contraintes de temps ajoutent aux défis auxquels sont confrontés les radiologues, impactant potentiellement leur capacité à fournir des diagnostics précis et en temps opportun de manière constante. Pour relever ces défis, une formation continue, l'adoption de technologies d'imagerie avancées et le développement d'outils de soutien à la décision sont nécessaires afin d'assister les radiologues dans la compréhension des mammographies complexes et d'améliorer les résultats des patients. Les difficultés rencontrées par les radiologues pour interpréter les mammographies.

3. Les bases de données de mammographie

Comme nous l'avons déjà évoqué, le cancer du sein demeure un enjeu majeur de santé publique à l'échelle mondiale, mettant en évidence l'importance cruciale de développer des outils de diagnostic à la fois précis et performants. La mammographie, en tant que méthode de dépistage principale, revêt une importance clé dans le diagnostic précoce du cancer du sein. Néanmoins, l'analyse des mammographies par les radiologues est intrinsèquement complexe et demeure susceptible d'erreurs humaines. Afin de surmonter ces obstacles et d'accroître la précision des diagnostics, les systèmes DAO se sont révélés être des outils essentiels pour assister les radiologues dans l'interprétation des mammographies. Dans cette optique, les bases de données mammographiques occupent une place centrale dans le développement et l'optimisation de ces systèmes DAO. En fournissant aux algorithmes de DAO un accès à une vaste gamme d'images mammographiques annotées, ces bases de données permettent aux systèmes d'apprentissage automatique de s'entraîner et de se perfectionner. En analysant de vastes ensembles de données, les systèmes de DAO peuvent acquérir la capacité de détecter des caractéristiques subtiles associées aux lésions mammaires malignes, ce qui contribue à améliorer la sensibilité et la spécificité des diagnostics. En intégrant les données provenant de ces bases dans leurs processus d'interprétation, les radiologues peuvent bénéficier d'une assistance supplémentaire pour détecter et caractériser les anomalies mammographiques, renforçant ainsi l'efficacité et la fiabilité du diagnostic. Ainsi, l'exploitation des bases de données mammographiques dans le contexte du DAO représente une avancée majeure dans la lutte contre le cancer du sein, offrant de nouvelles perspectives afin d'optimiser les résultats cliniques et la qualité des soins.

3.1. Importance des bases de données mammographiques

Dans le secteur de la radiologie mammographique, les bases de données jouent un rôle vital en fournissant une infrastructure essentielle pour le développement et l'amélioration des

systèmes DAO. Ces bases de données agissent comme des réservoirs riches en images mammographiques annotées, offrant aux chercheurs et aux développeurs d'algorithmes un accès à une diversité d'exemples représentatifs de cas cliniques. Cette diversité est cruciale pour l'entraînement, le test et l'évaluation des algorithmes de DAO, puisqu'elle permet aux systèmes d'apprentissage automatique d'identifier et de généraliser les caractéristiques significatives liées aux lésions mammaires. L'étude approfondie de ces données permet aux systèmes de DAO d'acquérir la capacité de distinguer de façon précise les tissus mammaires normaux des anomalies potentiellement malignes, ce qui contribue directement à améliorer la précision et la fiabilité du diagnostic. En outre, l'utilisation de bases de données mammographiques à grande échelle permet aux chercheurs d'explorer de nouvelles approches et de tester de nouvelles idées, promouvant ainsi l'innovation et les avancées dans le secteur de la détection précoce du cancer du sein. En résumé, les bases de données mammographiques représentent une ressource précieuse qui sous-tend l'avancement continu des technologies de diagnostic assisté par ordinateur, ouvrant la voie à des améliorations significatives dans la prise en charge et le traitement du cancer du sein.

3.2. Généralités sur Les Bases de Données Mammographiques

Les bases de données mammographiques constituent des ensembles de données variés et complexes, regroupant une multitude d'images radiographiques du sein, accompagnées de métadonnées pertinentes telles que l'âge du patient, les antécédents médicaux, les résultats histologiques, etc. Ces bases de données sont généralement composées d'une variété de types d'images mammographiques, notamment les mammographies numériques (Full Field Digital Mammography : FFDM) et les mammographies scannées (Scanned Film Mammography : SFM), chacune présentant ses propres caractéristiques et défis d'interprétation. Les caractéristiques principales des bases de données mammographiques comprennent leur taille, leur diversité et leur qualité. Concernant la taille, ces bases de données peuvent varier considérablement en fonction du nombre d'images et de patients qu'elles contiennent, allant de quelques centaines à plusieurs milliers voire millions d'images. Une taille suffisamment grande est cruciale pour garantir la représentativité de la population étudiée et pour permettre un entraînement efficace des algorithmes de DAO. La variété des images mammographiques présentes dans ces bases de données est également cruciale, car elle reflète la variabilité naturelle des présentations cliniques du cancer du sein. Cette diversité inclut différentes densités mammaires, Diverses lésions (microcalcifications, masses, asymétries, etc.), ainsi que des différences d'éclairage, de qualité de l'image et d'angles de vue. Une telle diversité garantit que les algorithmes de DAO sont exposés à une gamme représentative de cas cliniques, ce qui renforce leur capacité à généraliser et à fournir des résultats précis dans des situations réelles. Enfin, la qualité des images mammographiques dans ces bases de données est un aspect critique. Les images peuvent être stockées dans différents formats, tels que DICOM, PGM, ou LJPEG, chacune ayant ses propres caractéristiques et niveaux de compression. En outre, les bases de données peuvent inclure des images de résolutions différentes, allant des images haute résolution à celles de résolution standard, ce qui a des conséquences directes sur la qualité et la précision du diagnostic. Une haute qualité d'image est nécessaire pour permettre une interprétation précise par les radiologues et pour assurer l'efficacité des algorithmes de DAO. Cela implique une résolution spatiale élevée, un faible niveau de bruit et une absence d'artefacts techniques susceptibles de compromettre la visibilité des lésions. En somme, les bases de données mammographiques constituent des ressources fondamentales dans la recherche sur le cancer du sein et le développement de technologies de diagnostic avancées. Leur diversité, leur taille, et leur qualité en font des outils inestimables pour l'entraînement, le test et l'évaluation

des algorithmes de diagnostic, contribuant ainsi à l'optimisation des pratiques cliniques et des résultats pour les patients.

3.3. Les Bases de Données Mammographiques existants

La présence de bases de données mammographiques numériques et numérisées est un élément clé dans la recherche sur le cancer du sein et le développement de technologies de diagnostic avancées. Ces bases de données contiennent une large gamme d'images radiographiques du sein, accompagnées de données cliniques et de métadonnées cruciales. L'analyse de ces bases de données offre une occasion unique de saisir la variabilité naturelle des manifestations cliniques du cancer du sein et de concevoir des DAO plus performants. Dans cette sous-section, nous examinerons en détail les bases de données mammographiques existants, en mettant en lumière leur diversité, leur importance et leur impact sur la recherche et la pratique clinique.

3.3.1. MIAS

La base de données MIAS[33], publiée en 1994, est accessible sur le site « <http://peipa.essex.ac.uk/info/mias.html> » (consulté le 26 Mars 2024) sans aucune exigence d'inscription. Chaque anomalie enregistrée dans la base de données inclut des informations sur la densité mammaire, le type d'anomalie, son degré de gravité, ainsi que les coordonnées x et y indiquant le centre de l'anomalie sur l'image, ainsi que le rayon approximatif d'un cercle englobant l'anomalie. L'origine du système de coordonnées est située dans le coin inférieur gauche. Chaque anomalie d'image est classée dans l'une des sept catégories suivantes : calcifications, masses bien définies/circulaires, masses épineuses, autres masses mal définies, distorsion architecturale, asymétrie et normal. La base de données ne contient que des images de la vue MLO, chaque patient disposant à la fois une vue MLO gauche (LMLO) et une vue MLO droite (RMLO), stockées au format « Portable Gray Map (PGM) ».

La base de données présente un désavantage : les images sont de petite taille, avec une résolution de 1024×1024 pixels. Cette résolution limitée peut éventuellement conduire à une perte significative d'informations concernant les masses de petite taille et les microcalcifications. Par ailleurs, plusieurs mammographies de la base de données peuvent présenter des erreurs de positionnement du sein et des anomalies. [34]. Étant donné que les images ont été acquises à l'aide de la numérisation, elles peuvent contenir des éléments inutiles (comme le montre la Figure 14). Ces éléments pourraient avoir un impact négatif lors de l'entraînement des réseaux neuronaux, et par conséquent, leur suppression devrait être envisagée.



Figure I. 13: : figure représente les éléments inutiles et les erreurs de positionnement [35]

3.3.2. CBIS-DDSM

Le *CBIS-DDSM*[36] (CBIS-DDSM) est une version mise à jour et standardisée du DDSM[37]. Ce sous-ensemble présente une segmentation de la région d'intérêt (ROI) actualisée, Les boîtes de délimitation, ainsi que les images, ont été décompressées et transformées au format DICOM, lequel est reconnu comme un format standard pour l'ensemble des images médicales. La base de données DDSM originale a été publiée en 1997. Le jeu [36] de données peut être obtenu gratuitement sur « <https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=22516629> » (consulté le 26 mars 2024). Pour télécharger les données, un récupérateur de données NBIA est requis, qui est un logiciel spécialisé pour ouvrir les fichiers manifestes TCIA (The Cancer Imaging Archive) à partir du site web.

La base de données CBIS-DDSM est divisé en deux groupes en fonction du type d'anomalie, qui sont les calcifications et les masses. Chaque catégorie d'anomalies contient un ensemble d'entraînement et un ensemble de test. La base de données offre des informations complémentaires pour chaque anomalie détectée, y compris la densité mammaire normalisée selon l'ACR, l'évaluation du BI-RADS, les résultats de la pathologie, ainsi que l'évaluation de la subtilité de l'anomalie. Pour les découvertes de calcifications, des informations sur leur type et leur distribution sont incluses, tandis que pour les découvertes de masse, des informations sur leur forme et leurs marges sont fournies. La ROI (Région d'Intérêt) est définie par le masque binaire. Les images dans La base de données CBIS-DDSM sont en haute résolution, avec de légères variations de résolution entre les images. Le traitement du jeu de données CBIS-DDSM a présenté plusieurs défis[35]. Certaines des difficultés rencontrées comprennent :

1. Images inversées : Certaines images dans La base de données étaient inversées, où le positionnement du sein dans l'image MLO (Médio-Latérale Oblique) droit semblait être le même que celui dans l'image MLO gauche, et vice versa.
2. Noms de fichiers incohérents : Les noms de fichiers des images ne correspondaient pas toujours aux noms de fichiers dans le fichier CSV de description accompagnant.
3. Disparités de résolution : Certains masques dans La base de données avaient une résolution différente de celle de l'image originale. Cela nécessitait le redimensionnement des masques pour correspondre à la résolution des images correspondantes, assurant l'alignement approprié et la localisation précise des anomalies.
4. Masques de calcifications surdimensionnés : Certains masques de calcifications dans La base de données étaient surdimensionnés et n'indiquaient pas avec précision la présence de calcifications dans les zones correspondantes des images.
5. Éléments redondants dans les images : Similaire à la base de données MIAS, les images dans La base de données CBIS-DDSM peuvent contenir des éléments redondants en raison de l'acquisition avec la technologie SFM (mammographie scan-film).
6. Artéfacts dans les mammographies : Certaines mammographies dans La base de données peuvent contenir des artéfacts, ce qui pourrait affecter la précision et la fiabilité de l'analyse.

Ces enjeux mettent en évidence la nécessité des processus de prétraitement et de nettoyage des données lors de l'utilisation d'ensembles de données d'images médicales, afin d'obtenir des résultats précis et fiables dans les tâches d'analyse et de modélisation subséquentes.

3.3.3. INbreast

La base de données INbreast[38] représente une ressource significative dans le domaine de la mammographie numérique, mise à disposition par l'Hôpital de São João, à Porto, Portugal, en 2011. Cette base de données comprend un ensemble exhaustif de 410 images mammographiques numériques haute résolution, stockées au format DICOM, accompagnées d'une segmentation polygonale détaillée dans un fichier XML distinct au format OSIRIX. Les images contenues dans la base de données INbreast englobent une gamme d'anomalies mammaires, y compris des masses, des calcifications, des asymétries et des distorsions.

Une caractéristique clé de la base de données INbreast est la confirmation histologique de toutes les pathologies, obtenue par biopsie par carottage ou par évaluation de spécimens post-chirurgicaux. Cette confirmation histologique améliore la crédibilité et l'exactitude des données, augmentant ainsi leur utilité dans le domaine de la recherche médicale et dans l'analyse des techniques de diagnostic. La qualité des annotations dans INbreast a été soigneusement vérifiée pour garantir une précision maximale. Cette attention aux détails a conduit INbreast à être reconnu comme l'un des ensembles de données mammographiques open-source les plus fiables et précis disponibles.

En termes d'accès, les dernières années, les auteurs d'INbreast ont choisi de ne pas imposer de restrictions de licence spécifiques, permettant ainsi un accès libre aux chercheurs et aux fournisseurs commerciaux. Cela encourage le travail collaboratif et l'innovation dans le secteur de la mammographie numérique, offrant ainsi à une diversité de professionnels de la santé et de chercheurs l'opportunité de tirer parti de cette ressource. Néanmoins, il est important de souligner que, malgré ses atouts, la taille relativement restreinte de la base de données INbreast pourrait en restreindre l'applicabilité dans certaines situations.

3.3.4. BCDR

Le Breast Cancer Digital Repository (BCDR)[39, 40] a été initié en 2012 dans le but de collecter, de numériser et de structurer les mammographies sur film provenant du programme portugais de dépistage du cancer du sein, dans le but de faciliter de futures initiatives de recherche. Au départ, la base était constituée de 3 703 mammographies sur film numérisées. Chaque image au sein du répertoire RNCS-F est stockée sous forme de fichier TIFF 8 bits avec une résolution de 1168×720 pixels. Il est à noter que l'étiquetage de ces images est conforme aux normes BIRADS.

Cependant, des barrières d'accessibilité entravent l'utilisation généralisée [40] de la base de données BCDR. L'accès est généralement restreint aux institutions académiques dotées de plans de projet formels et d'objectifs non commerciaux, contrôlé par un processus de demande rigoureux. Parmi les 3 703 mammographies dans le répertoire, la répartition selon les différentes classifications BIRADS (Masse, Microcalcification, Calcification, Distorsion). Des segmentations polygonales sont fournies pour les classes positives, bien que seul un sous-ensemble de ces constatations soit confirmé par l'histologie, le reste étant basé uniquement sur l'opinion clinique. De plus, les annotations sont exclusivement fournies pour les lésions, sans métadonnées disponibles pour les tissus environnants.

Malgré l'arrêt de la maintenance active pour le répertoire BCDR-F original, un projet supplémentaire, BCDR-D, continue d'accumuler des mammographies numériques en champ complet stockées sous forme de fichiers TIFF 16 bits à une résolution plus élevée de 3328×2560 pixels. À l'heure actuelle, RNCS-D comprend plus de 3 600 images, également conformes aux

normes BIRADS. Cependant, la nature chronophage du processus de demande d'accès au jeu de données présente un défi notable pour les utilisateurs potentiels.

3.3.5. OPTIMAM (OMI-DB)

La base de données OMI-DB (Optimam Medical Image Database) [41] se distingue des bases de données précédentes par sa croissance continue en taille chaque année. Elle rassemble des images et des données provenant de divers centres de dépistage à travers le Royaume-Uni, y compris des images ne présentant aucun résultat suspect. En raison de la structure complexe de cette base de données, l'utilisation du package Python "omidb" est recommandée pour l'extraction et le traitement des informations qu'elle contient.

Bien que la base de données soit publiquement disponible, certaines limitations s'appliquent. L'accès à la base de données nécessite une justification du projet de recherche, et le demandeur doit avoir un historique de recherche pertinent ainsi qu'une affiliation avec une institution de santé, un centre académique, une organisation à but non lucratif ou une organisation commerciale. Des informations supplémentaires sur la manière d'obtenir l'accès peuvent être trouvées sur <https://medphys.royalsurrey.nhs.uk/omidb/getting-access/> (consulté le 27 mars 2024). Une fois le projet approuvé, le demandeur n'aura pas accès à l'ensemble des données, mais devra spécifier les données avec lesquelles il préfère travailler, telles que les images contenant un certain type de résultat.

La base de données OMI-DB [26] contient actuellement des données de 179 326 patients. Il est important de noter qu'un patient peut avoir plusieurs épisodes malins ou bénins. La malignité d'un résultat est déterminée par biopsie. Les images dans la base de données sont stockées au format DICOM, et pour chaque patient, il peut y avoir des informations sur la ROI (région d'intérêt) pour plusieurs vues (par exemple, MLO + CC) décrites avec des rectangles de délimitation. Chaque rectangle contient des informations sur le type de résultat, et plusieurs résultats (par exemple, masse + calcifications + distorsion architecturale) peuvent être présents dans un seul rectangle. Les résultats les plus courants dans la base de données sont les masses et les calcifications suspectes.

Un avantage significatif de la base de données OMI-DB est qu'elle inclut des mammographies antérieures provenant d'examens de dépistage, prises avant que le résultat ne se développe ou ne soit détecté. Cela offre une opportunité d'étudier l'évolution des résultats au fil du temps. Parmi les autres atouts de la base de données, on trouve l'abondance de données disponibles ainsi qu'une représentation accrue de résultats rares, tels que les distorsions architecturales et les asymétries. Cependant, un inconvénient de la base de données est sa complexité, car elle peut nécessiter un temps de traitement supplémentaire en raison des exceptions et des cas limites.[40]

3.3.6. VinDr-Mammo

L'ensemble de données VinDr-Mammo[42] représente une ressource précieuse et novatrice pour le développement de techniques avancées d'analyse mammographique assistée par ordinateur. Composé de 5 000 examens de mammographie numérique plein champ (FFDM), recueillis entre 2018 et 2020 à partir des systèmes d'archivage et de communication d'images (PACS) de deux éminents établissements médicaux au Vietnam, l'Hôpital Universitaire Médical de Hanoi (HMHU) et l'Hôpital 108 (H108), cette base de données offre une représentation diversifiée et riche en données de la mammographie numérique. Chaque examen

est constitué de quatre vues standard, assurant une couverture exhaustive et multidimensionnelle de la structure mammaire.

Afin de garantir la qualité et la fiabilité des annotations, chaque examen est relu en double par trois radiologistes expérimentés, conformément aux directives européennes, afin de garantir la précision des données fournies. Les annotations sont réalisées selon le système de déclaration et de données en imagerie mammaire (BI-RADS), facilitant ainsi une analyse approfondie de la densité mammaire et des anomalies potentielles identifiées. Les zones présentant des caractéristiques anormales, nécessitant un suivi ou suspectes de malignité, sont minutieusement marquées par des rectangles de délimitation, facilitant ainsi leur identification et leur analyse ultérieure. En outre, la base est stratifiée en ensembles d'entraînement et de test, conformément aux meilleures pratiques de développement d'algorithmes d'apprentissage automatique, tout en préservant la distribution des caractéristiques importants et essential. Cette approche assure que les modèles élaborés à partir de la base VinDr-Mammo sont à la fois représentatifs et généralisables. Enfin, la publication de cette base de données sur la plateforme <https://physionet.org/> en fait une ressource précieuse et accessible pour la communauté scientifique, encourageant de ce fait le travail collaboratif et le progrès dans le secteur du dépistage du cancer du sein utilisant la mammographie numérique à grand champ[42].

3.3.7. EMBED

La base de données EMBED (*EMory BrEast imaging Dataset*)[43] est une ressource exceptionnelle dans le domaine de l'imagerie mammaire. Composé de 3,4 millions d'images mammographiques de dépistage et diagnostiques, cette base de données résulte d'une collaboration entre l'Université Emory, la Mayo Clinic et le laboratoire Hitty à l'ASU.

Ce qui le distingue des autres bases de données est sa grande diversité, avec un nombre équilibré de patients noirs et blancs, et des informations sur la race auto-déclarée incluses. La raison fondamentale de l'élaboration de cet ensemble de données était de pallier l'insuffisance de diversité constatée dans les jeux de données mammographiques existants, tout en améliorant la détection du cancer du sein.

Avec ses 115 000 patients collectés entre 2013 et 2020, dont l'âge moyen se situe entre 50 et 60 ans, La base de données EMBED offre une vue précieuse sur la pathologie mammaire. Il comprend également des lésions classées comme ambiguës, ainsi qu'un prétraitement appliqué en fonction du fabricant. Avec une taille impressionnante de 16 téraoctets, La base est stockée dans une base de données MongoDB hébergée sur les serveurs d'Emory. Bien qu'un sous-ensemble de 20 Go soit disponible sur Amazon, l'accès complet au jeu de données peut être demandé via des partenariats de recherche ou industriels.

De plus, cette base de données intègre des fichiers DICOM ainsi que des métadonnées associées, et son extraction peut être réalisée à l'aide du code Niffler, qui est open source. Ce jeu de données a été utilisé dans de nombreux projets et articles internes, et a été inclus dans un défi de mammographie organisé par la RSNA. Il peut être utilisé pour l'entraînement, l'examen des modèles préexistants et l'exploration des données. Néanmoins, il convient de souligner que cette base de données n'inclut pas d'examens en DBT, en échographie ou en IRM. Malgré son utilité, La base de données EMBED présente également quelques défis, notamment sa complexité, qui peut nécessiter un temps de traitement supplémentaire en raison de cas particuliers. En fin de compte, La base de données EMBED représente une ressource précieuse pour la recherche en imagerie mammaire, offrant une diversité et une richesse d'informations inestimables pour les chercheurs et les cliniciens[43].

3.4. Analyse comparative des caractéristiques des bases de données

Grâce aux bases de données mammographiques évoquées précédemment, résumés dans les Tableaux 2 et 3, la sélection a été basée sur leur pertinence pour la recherche académique et l'accès à des données d'imagerie mammographique exhaustives qu'elles contiennent. Chacun de ces ensembles de données offre des ressources précieuses pour l'analyse et l'évaluation des techniques d'imagerie mammaire. Ils exhibent des différences dans des éléments essentiels, offrant ainsi une variété de caractéristiques pour des recherches futures. Ces variations peuvent être catégorisées dans les domaines suivants :

1. **Origine** : se réfère à l'origine des données au sein de la base de données, précisant leur source d'acquisition.
2. **Volume** : Le nombre de mammographies incluses dans chaque ensemble de données varie, allant de quelques centaines à plusieurs milliers. Cette diversité facilite des recherches avec des tailles d'échantillon et des puissances statistiques différentes.
3. **Source de l'image** : Les collections de données incluent des mammographies issues de diverses techniques d'imagerie. Certains de ces ensembles se composent de mammographies obtenues à l'aide de capteurs numériques, appelées mammographies numériques, tandis que d'autres incluent des mammographies sur films numérisés. Cette variation permet d'étudier l'impact des différentes technologies d'imagerie sur les performances des algorithmes d'analyse.
4. **Résolution de l'image** : La résolution à laquelle les images mammographiques ont été capturées varie selon les ensembles de données. Cette fluctuation influence la précision et la clarté des images accessibles pour l'analyse.
5. **Format de l'image** : Les ensembles de données contiennent des images mammographiques au format varié, incluant DICOM, TIFF et JPG. En outre, certaines bases de données peuvent être soumises à des méthodes de compression afin de minimiser l'espace de stockage requis. Le choix du format et les éventuelles compressions peuvent influencer l'accessibilité et la qualité des images.
6. **Données cliniques** : Les données médicales associées à chaque image, telles que l'âge du patient ou les antécédents médicaux.
7. **Classification BI-RADS** : La catégorisation définie par le système BI-RADS pour analyser les résultats des mammographies.
8. **Anomalies** : La détection et le type d'anomalies mammaires observées, telles que les masses, les calcifications ou les distorsions.
9. **Étiquetage des lésions** : Les ensembles de données varient quant à la façon dont les lésions sont annotées. Certains d'entre eux attribuent des étiquettes à l'ensemble de la mammographie, tandis que d'autres se concentrent sur des lésions particulières en recourant à des coordonnées de boîte englobante ou à des cartes de segmentation polygonale. Cette diversité offre la possibilité d'évaluer les performances des algorithmes dans divers contextes de détection et de localisation des lésions.
10. **Disponibilité/ Accessibilité** : Les bases de données varient en termes d'accessibilité. Certains ensembles de données sont disponibles gratuitement, permettant aux chercheurs d'y accéder et de les utiliser sans aucune restriction. D'autres peuvent être open source mais soumis à certaines conditions de licence, tandis que quelques ensembles de données nécessitent un abonnement payant ou un accord de licence pour y accéder. Cette disparité en matière d'accessibilité peut avoir un impact sur la disponibilité et l'adoption généralisée des ensembles de données au sein de la communauté de recherche.

Tableau I. 2: Caractéristiques techniques et descriptives des bases de données mammographiques

Base de Données	Année	Origine	Volume		Source de l'image	Format de l'image	Résolution
			Nombre de patients	Nombre d'images			
MIAS	1994	ROYAUME-UNI	161	322	SFM	PGM	1024*1024
DDSM	1996	Etats-Unis	2620	Over of 10000	SFM	LJPEG	4084*3328
BCDR-F	2012	Portugal	1010	3703	SFM	TIFF	1167*720
INBREAST	2012	Portugal	115	410	FFDM	DICOM	4084*3328 3328*2560
CBIS-DDSM	2016	Etats-Unis	2620	Over of 10000	SFM	DICOM	4084*3328
OPTIMAM	2021	ROYAUME-UNI	172,282	3072878	FFDM	DICOM	Haute qualité mais Pas spécifié
VIN-Dr MAMMO	2022	Vietnam	5000	20000	FFDM	DICOM	3518*2800
EMBED	2023	Etats-Unis	115910	Total : 3.4M Images (+58% Mammograms)	FFDM	DICOM ; PNG	Haute qualité mais Pas spécifié

Plusieurs différences significatives émergent parmi les ensembles de données accessibles, incluant des éléments tels que la qualité d'image, le volume des données, et le système d'étiquetage, le type d'imagerie et les conditions de licence. Ces variations contribuent à un paysage d'interopérabilité médiocre, entravant le développement d'outils généralisables et validés cliniquement pour l'imagerie mammographique.

Une distinction clé parmi les ensembles de données réside dans leurs cas d'utilisation clinique, qui s'alignent souvent sur des objectifs de recherche spécifiques. Par exemple, tandis que l'ensemble de données MIAS peut être adapté à l'évaluation des tissus de fond, il peut ne pas répondre aux exigences des chercheurs se concentrant sur la détection des lésions. D'un autre côté, la base de données INbreast pourrait s'avérer extrêmement précieuse pour les équipes de recherche qui travaillent sur des systèmes de triage pour la mammographie complète, axés sur des résultats binaires tels que la détection de tumeurs malignes. Par ailleurs, la distinction entre les images sur film et numériques est cruciale lors de la sélection des ensembles de données. Bien que la mammographie numérique soit majoritaire dans les pays développés, l'inclusion de mammographies sur film reste cruciale, notamment pour les entreprises commerciales cherchant à étendre le dépistage mammographique aux économies en développement où les scanners sur film sont encore prévalents.

Tableau I. 3:Caractéristiques d'annotation et d'accessibilité

Base de données	Anomalie	Étiquetage de lésion	Classification BI-RADS	Données cliniques	Disponibilité
MIAS	Varié	Circle	-	-	Publique
DDSM	Mass, Calcification	Polygonal	-	✓	Publique
BCDR-F	Varié	Polygonal	✓	✓	Sur demande
INBREAST	Varié	Polygonal	✓	✓	Publique
CBIS-DDSM	Mass, Calcification	Polygonal	-	✓	Publique
OPTIMAM	Varié	Polygonal	Disponible uniquement pour l'ensemble traité	✓	Privé/ Commercial
VIN-Dr MAMMO	Varié	Boîte Englobante	✓	✓	Sur demande
EMBED	Varié	Polygonal	✓	✓	Privé (seulement 20% sur demande)

L'interopérabilité et la normalisation présentent des défis supplémentaires, car les ensembles de données utilisent fréquemment des schémas d'annotation et des formats d'image variés. Des stratégies de standardisation, telles que l'utilisation d'un seul format d'image sans perte tel que DICOM[44], pourraient renforcer l'interopérabilité des ensembles de données et simplifier le partage ainsi que l'analyse des informations. Il est également important de prendre en compte le volume des données, En effet, des ensembles de données plus volumineux, tels qu'OPTIMAM, offrent une utilité accrue pour la recherche en apprentissage automatique, facilitant la création de modèles plus fiables et performants. Néanmoins, même des ensembles de données de taille réduite, tels qu'INbreast, conservent leur pertinence, notamment lorsqu'ils sont enrichis à l'aide de méthodes de génération de données synthétiques. Il est également notable qu'il existe un manque d'ensembles de données d'origine africaine (pour les femmes vivant en Afrique). Cette lacune suscite des interrogations concernant l'effet que pourraient avoir les outils créés à partir de ces ensembles de données sur les femmes en Afrique, où l'incidence du cancer du sein demeure préoccupante. Comblé cette lacune pourrait être crucial pour garantir l'applicabilité et l'efficacité des outils d'imagerie mammographique dans des populations diverses.

En conclusion, aborder ces disparités et exploiter les forces des ensembles de données diversifiés sont des étapes essentielles pour faire progresser le domaine de l'imagerie mammographique. En encourageant la coopération, la standardisation et l'utilisation de techniques d'augmentation de données, les chercheurs sont en mesure de surmonter les obstacles actuels et de stimuler l'innovation dans le domaine de la détection et du diagnostic du cancer du sein et radiologie en général.

4. Conclusion

À l'issue de cette exploration approfondie, il est évident que la compréhension du cancer du sein est une pierre angulaire pour le développement de techniques d'imagerie médicale efficaces. Ce chapitre a souligné les multiples facettes complexes de cette maladie, allant des facteurs de risque à la prévention, tout en abordant les techniques de dépistage et de diagnostic. La mammographie numérique a été présentée en tant qu'outil clé pour identifier précocement le cancer du sein, dont l'interprétation revêt une importance capitale pour fournir des résultats cliniquement significatifs. Nous avons exploré en détail les défis auxquels sont confrontés les radiologues dans l'interprétation des mammographies, notamment en ce qui concerne la classification BI-RADS et la détection des anomalies. De plus, l'importance des bases de données d'images mammographiques pour la recherche et la pratique clinique a été mise en avant. Nous avons examiné plusieurs de ces bases de données existantes, analysant leurs caractéristiques et leurs fonctionnalités. Cependant, nous avons également constaté des disparités importantes entre ces bases de données, ce qui compromet leur interopérabilité et leur utilité pour le développement d'outils généralisés et validés cliniquement. Un point crucial soulevé dans ce chapitre est l'absence de bases de données d'origine africaine, ce qui soulève des préoccupations importantes quant à l'applicabilité des outils d'imagerie mammographique dans les populations africaines, où le cancer du sein reste un problème de santé majeur.

En résumé, afin d'avancer dans ce domaine de l'imagerie mammographique, il est impératif de promouvoir la collaboration entre chercheurs, de standardiser les approches et d'explorer des stratégies novatrices d'augmentation des données. En surmontant les défis existants et en capitalisant sur les forces des différentes bases de données, nous pouvons envisager la création d'outils plus performants pour la détection précoce et le diagnostic précis du cancer du sein.

Dans le chapitre suivant, nous analyserons en profondeur les enjeux liés à la détection et à la classification du cancer du sein. Cette analyse sera étayée par une revue exhaustive des solutions avancées dans la littérature pour résoudre cette problématique. Nous procéderons à une analyse critique des points forts et des limites de ces méthodes, afin de justifier et d'expliquer le choix méthodologique retenu pour notre étude.

CHAPITRE II :
Diagnostic Assisté par Ordinateur
pour le Cancer du Sein



Chapitre II : Diagnostic Assisté par Ordinateur pour le Cancer du Sein

1. Introduction

La lutte contre le cancer du sein se positionne comme une priorité globale dans le domaine de la santé publique à travers le monde, comme indiqué dans le chapitre précédent. Étant la première cause de décès par cancer chez les femmes, une détection précoce est essentielle pour augmenter les taux de survie et diminuer la mortalité[1]. La mammographie, méthode d'imagerie médicale largement utilisée, occupe une place centrale dans la détection et le diagnostic précoce de cette affection. Cependant, l'interprétation des mammographies peut être complexe et sujette à des erreurs, d'où la nécessité de technologies avancées pour soutenir les radiologues dans leur prise de décision[29].

Dans ce contexte, l'intelligence artificielle émerge comme une solution prometteuse. Avec des méthodes telles que l'apprentissage automatique et l'apprentissage profond, il est désormais possible de créer des systèmes capables d'analyser automatiquement les images de mammographies avec une précision impressionnante. Ces innovations technologiques pourraient radicalement changer les méthodes cliniques en optimisant la précision, l'efficacité et la vitesse du diagnostic du cancer du sein [45].

Ce chapitre a pour objectif de fournir une vue d'ensemble exhaustive des techniques actuelles de détection et de diagnostic du cancer du sein, avec un focus particulier sur les méthodes qui intègrent l'intelligence artificielle dans l'analyse de mammographies. Nous commencerons par examiner les applications de la vision par ordinateur dans l'analyse d'images médicales, en détaillant les différentes stratégies de segmentation, d'identification des anomalies et de classification des lésions. Nous examinerons également les DAO qui intègrent des algorithmes d'apprentissage automatique et profond.

Enfin, nous aborderons les défis et les limites actuels des approches basées sur l'IA, ainsi que les perspectives et les avancées récentes dans ce domaine en pleine évolution. Cette analyse soulignera l'importance croissante des technologies intelligentes dans l'amélioration de la détection et du diagnostic du cancer du sein, tout en mettant en évidence les opportunités et les défis futurs.

2. Vision par ordinateur (CV) dans l'Analyse d'Images Médicales

La vision par ordinateur (Computer Vision, CV) constitue une avancée significative au sein du domaine de l'imagerie médicale, introduisant des approches révolutionnaires pour identifier et traiter les pathologies, avec une attention particulière portée au cancer du sein. Ce domaine de l'intelligence artificielle se concentre sur la création et l'application d'algorithmes et de techniques qui autorisent les systèmes informatiques à analyser et à appréhender le contenu des images médicales, incluant les mammographies, les images par résonance magnétique (IRM) et les clichés radiographiques. L'importance de la CV réside dans sa capacité à améliorer la précision diagnostique, à optimiser l'efficacité du flux de travail clinique et à faciliter la détection précoce des pathologies. En permettant une analyse automatisée des images et en délivrant des mesures quantifiables, les systèmes de vision par ordinateur peuvent assister les radiologues dans leurs décisions, notamment en détectant les anomalies et en émettant des alertes préventives.

L'évolution historique de la CV dans l'analyse d'images médicales remonte aux premières étapes de l'imagerie numérique, où des méthodes de traitement d'images basiques étaient utilisées pour la visualisation et l'analyse. Toutefois, avec l'avènement de l'apprentissage automatique et de l'apprentissage profond, des avancées significatives ont été réalisées dans le domaine de la vision par ordinateur, offrant une précision accrue dans l'extraction de caractéristiques, une amélioration dans la détection de motifs et une fiabilité supérieure dans la classification d'anomalies au sein des images médicales. Les techniques sophistiquées de segmentation d'images et les CNN se sont établis comme des outils essentiels puissants pour délimiter les structures anatomiques et les lésions, affichant des performances exceptionnelles dans diverses tâches d'analyse d'images[46]

La vision par ordinateur dans le domaine médical englobe une vaste gamme de fonctions clés, incluant la classification, la segmentation et la détection, indispensables à l'interprétation des images médicales. Ces activités sont primordiales pour extraire des informations pertinentes à partir des images, facilitant ainsi le travail des cliniciens dans leur diagnostic et leur prise de décision[46]. La classification implique l'assignation d'étiquettes ou de catégories aux images selon des caractéristiques spécifiques, facilitant ainsi la distinction entre divers types de tissus ou de lésions. Par exemple, une image mammographique peut être classifiée comme présentant une anomalie suspecte ou étant normale. La segmentation implique la délimitation précise des structures anatomiques ou des régions d'intérêt dans l'image, facilitant une analyse plus détaillée et précise. Concernant le cancer du sein, la segmentation aide à séparer et définir les lésions cancéreuses des tissus non affectés alentour. Pour conclure, la détection a pour but de repérer et d'identifier de manière automatique les zones pertinentes, comme les anomalies ou les lésions, présentes dans l'image médicale. Ces tâches de CV sont étroitement intégrées dans les systèmes DAO, qui combinent des algorithmes sophistiqués avec l'expertise humaine pour améliorer la précision et l'efficacité du diagnostic du cancer du sein.[21, 45, 46]

Cependant, malgré les progrès réalisés, l'application de la CV à l'imagerie médicale pose plusieurs défis. Ceux-ci comprennent[45] :

1. **Qualité et diversité des données** : L'excellence des données est fondamentale pour garantir l'efficacité des modèles de vision par ordinateur. Les images médicales présentent une grande variabilité en ce qui concerne les paramètres d'acquisition, la qualité d'image et l'anatomie des patients, ce qui constitue un défi pour la généralisation des algorithmes.

2. **Puissance de calcul** : Les modèles sophistiqués de vision par ordinateur nécessitent souvent d'importantes ressources de calcul, ce qui peut poser un problème pour certaines institutions de santé qui n'ont pas accès à des ressources informatiques adéquates.

3. **Complexité des données visuelles** : Les images médicales sont souvent complexes et contiennent une grande quantité d'informations, rendant difficile l'identification des caractéristiques pertinentes pour la tâche à accomplir.

4. **Interprétabilité** : Assurer l'interprétabilité des modèles de CV est crucial pour leur acceptation clinique et leur fiabilité. Comprendre comment le modèle arrive à ses prédictions est essentiel pour valider ses décisions.

5. **Confidentialité et sécurité des données** : Les données d'imagerie médicale sont sensibles et doivent respecter des réglementations strictes en matière de confidentialité. Créer des systèmes de vision par ordinateur capables d'analyser ces données tout en protégeant la vie privée des patients constitue un défi important.

6. **Intégration avec le flux de travail clinique** : L'intégration fluide des systèmes de vision par ordinateur dans les flux de travail cliniques actuels présente des défis tant techniques que logistiques. Garantir la compatibilité avec les systèmes et protocoles de radiologie déjà en place est crucial pour une adoption à grande échelle.

7. **Validation clinique** : Toute technique développée doit être validée cliniquement, un processus souvent long et coûteux.

8. **Adhésion aux politiques locales et internationales** : Les solutions de CV en santé doivent se conformer à une variété de réglementations locales et internationales, ce qui peut représenter un défi en termes d'adhésion aux normes.

Pour relever ces défis, une collaboration interdisciplinaire entre informaticiens, radiologues et professionnels de la santé est nécessaire pour développer des solutions de CV robustes et cliniquement pertinentes pour l'analyse d'images médicales.

3. Détection et Diagnostic Assistés par Ordinateur du Cancer du Sein

L'utilisation de systèmes informatisés pour le diagnostic est cruciale dans l'identification et le diagnostic précoces du cancer du sein, tirant parti des dernières avancées technologiques pour renforcer l'efficacité de ces démarches. Ces systèmes offrent un soutien précieux aux radiologues et aux cliniciens, leur permettant d'analyser les images médicales avec une précision accrue et une efficacité améliorée.

3.1. Les systèmes de DAO

Dans le domaine de l'imagerie médicale, le terme DAO fait référence à des systèmes informatiques conçus pour soutenir les médecins à prendre des décisions rapidement. L'imagerie médicale implique l'analyse de données visuelles que les praticiens doivent évaluer rapidement pour identifier les anomalies. L'analyse des images médicales est une tâche cruciale car l'imagerie est une modalité fondamentale pour le diagnostic précoce des maladies [28, 47]. Cependant, l'acquisition d'images de haute qualité doit équilibrer la nécessité de visuels clairs avec la nécessité de minimiser les dommages au corps humain. Des techniques comme l'IRM, les rayons X, l'endoscopie et l'échographie peuvent produire des images de haute qualité lorsqu'elles sont acquises avec une énergie élevée, mais de tels niveaux d'énergie peuvent être

nocifs. Par conséquent, les images sont souvent prises avec moins d'énergie, ce qui entraîne une qualité et un contraste inférieurs. Les systèmes DAO contribuent à rehausser la qualité des images, facilitant ainsi l'interprétation précise des images médicales et mettant en évidence les zones importantes. La technologie DAO englobe plusieurs éléments, y compris l'intelligence artificielle, CV et le traitement des images médicales. L'application principale des systèmes DAO est la détection des anomalies dans le corps humain, avec la détection des tumeurs étant une application typique. Manquer des tumeurs lors des dépistages initiaux peut conduire au cancer, soulignant l'importance d'une détection précise.[28, 46, 47]

3.2. Évolution des systèmes DAO

L'évolution des systèmes DAO a considérablement été remarquable, notamment dans la détection du cancer du sein. Les premiers systèmes DAO reposaient principalement sur des règles, s'appuyant fortement sur des algorithmes prédéfinis et sur l'extraction manuelle des caractéristiques. Ces systèmes marquaient les parties ou structures visibles dans l'image « DAO » et aidaient à évaluer ces structures. Au fil du temps, les avancées en IA et en apprentissage profond ont révolutionné les systèmes DAO, les rendant plus sophistiqués et capables de gérer des tâches complexes.[46]

Les systèmes DAO modernes utilisent des méthodes d'apprentissage automatique et d'apprentissage profond pour examiner de larges volumes de données, apprenant à partir de nombreux exemples afin d'améliorer leur précision. Ces systèmes alimentés par l'intelligence artificielle sont plus efficaces pour identifier des motifs et des anomalies subtiles qui pourraient échapper aux méthodes traditionnelles. Ces systèmes peuvent classifier et segmenter les tissus mammaires, identifier les microcalcifications et les anomalies architecturales, ainsi que de prédire la malignité des masses en se basant sur leur forme et leur taille. Cette progression a consolidé l'importance des systèmes de DAO dans l'identification du cancer du sein, les rendant indispensables dans le diagnostic médical contemporain.

3.3. Analyse comparative des systèmes DAO traditionnels et basés sur l'IA

Les systèmes traditionnels de DAO reposaient sur des caractéristiques sélectionnées à la main et des algorithmes régis par des règles, limitant ainsi leur sensibilité et leur précision. Fréquemment, cela se traduisait par un nombre important de faux positifs et de faux négatifs, dû à leur incapacité à s'ajuster à l'hétérogénéité des images médicales. La rigidité des méthodes traditionnelles signifiait également qu'elles nécessitaient une intervention manuelle étendue et étaient moins efficaces dans divers contextes cliniques. À l'inverse, les systèmes DAO fondés sur IA exploitent des modèles d'apprentissage automatique entraînés sur de vastes ensembles de données. Cela leur permet d'apprendre à reconnaître des motifs complexes et d'améliorer leurs performances au fil du temps. Ces systèmes présentent une sensibilité et une précision améliorées, diminuant ainsi le taux de faux positifs et de faux négatifs. Les systèmes DAO basés sur l'IA peuvent s'adapter automatiquement à de nouvelles données, les rendant plus robustes et polyvalents à travers différentes modalités d'imagerie et populations de patients. Ils offrent des capacités améliorées pour repérer les petites masses dans les tissus denses, détecter les distorsions architecturales et anticiper les types de masses avec une précision accrue. L'incorporation de IA dans les systèmes DAO a aussi optimisé le processus de travail des radiologues, leur permettant de se concentrer sur les aspects critiques de la prise de décision tandis que l'IA s'occupe des analyses préliminaires. Cette synergie entre l'IA et l'expertise humaine assure une meilleure précision diagnostique et efficacité, ce qui, en conséquence,

améliore les résultats pour les patients en ce qui concerne la détection et le diagnostic du cancer du sein. En conclusion, la transition des systèmes DAO traditionnels vers ceux alimentés par IA marque un progrès significatif dans le diagnostic du cancer du sein. Tandis que les systèmes classiques ont posé les bases, l'intégration de l'IA a propulsé la technologie DAO dans une ère de précision et de fiabilité accrues, permettant aux radiologues de prendre des décisions mieux informées et d'améliorer la qualité globale des soins médicaux.

3.4. Les étapes des systèmes DAO pour le Cancer du Sein

Les systèmes DAO destinés au cancer du sein comprennent plusieurs étapes cruciales. Chacune jouant un rôle crucial dans l'identification et l'analyse des anomalies mammaires. Ces phases permettent aux cliniciens de réaliser une évaluation détaillée et informée, facilitant ainsi leur travail et fournissant un deuxième avis pour aider les radiologues. Les étapes fondamentales des systèmes DAO incluent le prétraitement des images, l'identification et la segmentation des anomalies, et se concluent par la classification. La Figure II.1 représente le processus des systèmes DAO pour le cancer du sein[46, 48].

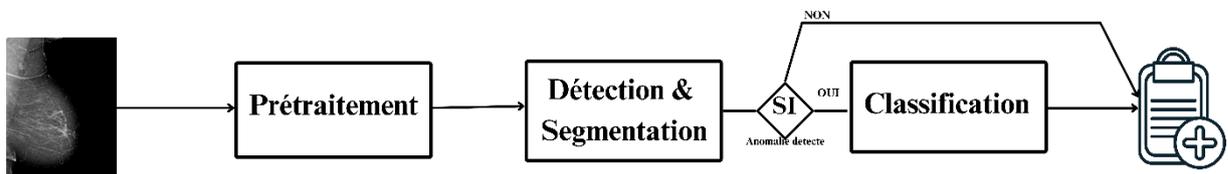


Figure II. 1: Les phases essentielles d'un DAO pour cancer du sein

3.4.1. Prétraitement des images

Le prétraitement des images représente une étape préliminaire essentielle dans les systèmes DAO. Cette étape est dédiée à l'amélioration de la qualité des images mammographiques, facilitant ainsi les analyses subséquentes. Voici quelques techniques fréquemment employées lors de cette phase [49, 50]:

- Filtrage des Images : Cette technique implique l'application de divers filtres pour atténuer le bruit présent dans les images et pour améliorer leur contraste. Cela permet d'accentuer les détails pertinents et de minimiser les éléments indésirables, rendant ainsi l'image plus claire et plus facile à analyser.
- Correction des Artéfacts : Les artéfacts sont des anomalies présentes dans les images qui peuvent entraver une analyse précise. Ces anomalies peuvent être dues à divers facteurs, tels que les mouvements du patient ou les erreurs d'imagerie. Leur élimination est donc essentielle pour garantir l'exactitude de l'interprétation des images.
- Normalisation : La normalisation vise à ajuster les variations d'intensité lumineuse présentes dans les images. En standardisant ces variations, on obtient une uniformité à travers l'ensemble de l'image, ce qui facilite grandement l'analyse et l'interprétation ultérieures.

En somme, le prétraitement des images est une étape essentielle qui prépare le terrain pour les phases d'analyse et de diagnostic plus avancées dans les systèmes DAO. Il est crucial pour augmenter la précision et l'efficacité de ces systèmes.

3.4.2. Détection et segmentation

La détection et la segmentation constituent des phases importantes des systèmes DAO pour le cancer du sein. Ces phases permettent d'isoler les régions d'intérêt dans les images mammographiques, facilitant ainsi l'analyse et l'interprétation par les cliniciens. Cette étape se scinde en deux sous-phases interconnectées : l'identification des anomalies et la segmentation.

A. Détection des Anomalies

Souvent, la première étape des systèmes DAO dédiés au cancer du sein est la détection des anomalies mammaires. Cette étape est cruciale car elle permet d'identifier les zones suspectes dans les images mammographiques qui peuvent indiquer la présence d'une tumeur. Dans cette phase, plusieurs techniques d'imagerie et d'analyse d'images sont utilisées. Par exemple, les méthodes de seuillage sont fréquemment utilisées pour séparer les masses des tissus mammaires adjacents en se fondant sur l'intensité des pixels. En outre, des techniques plus sophistiquées, telles que la transformée de Hough, peuvent être appliquées pour identifier des formes particulières qui pourraient signaler la présence d'une masse[51, 52] .

En outre, les CNNs, tels que AlexNet, VGGNet ou ResNet, sont de plus en plus utilisés dans cette phase. Ces réseaux ont la capacité d'apprendre à identifier des caractéristiques complexes dans les images, cela peut améliorer l'exactitude dans l'identification des masses. Des méthodes récentes de détection d'objets, comme YOLO, ont été appliquées avec succès dans le secteur de la mammographie. YOLO divise l'image en une grille et prédit simultanément plusieurs boîtes englobantes ainsi que les probabilités de classe, facilitant ainsi une détection rapide et précise des anomalies dans les images de mammographies[28, 53, 54]. En résumé, la détection des masses constitue une étape clé dans les systèmes DAO pour le dépistage du cancer du sein. Elle permet d'identifier les zones suspectes qui nécessitent une analyse plus approfondie, contribuant ainsi à un diagnostic précoce et précis.

B. Segmentation des Anomalies

La segmentation en traitement d'images désigne le processus consistant à diviser une image en plusieurs régions dans le but d'extraire la région d'intérêt en identifiant les masses dans les mammographies. La segmentation facilite ainsi la détection des anomalies. Toutefois, cette détection peut être perturbée par la présence de muscles pectoraux et d'artefacts, lesquels doivent être éliminés avant la segmentation. Ces éléments, qui ne font pas partie du sein, peuvent tromper les algorithmes de classification [55, 56]

Les techniques traditionnelles de segmentation s'appuient sur l'analyse numérique d'images et des principes mathématiques. Dans cette catégorie, les approches de segmentation par détection de bords comprennent des méthodes comme la détection de bords de Canny, les modèles de contours actifs et l'utilisation de l'opérateur de Sobel. Ces approches visent à identifier les bords des structures anatomiques présentes dans les images. En revanche, les techniques de segmentation par seuillage comprennent des approches telles que le seuillage par la méthode d'Otsu, le seuillage morphologique, le seuillage adaptatif, le seuillage manuel, le seuillage selon Kittler et le seuillage à l'échelle globale et locale. Ces stratégies utilisent les variations d'intensité des pixels pour diviser les images. Par ailleurs, les méthodes de segmentation par régions, incluant les algorithmes de Watershed, l'approche basée sur la théorie des ensembles approximatifs, l'expansion de régions et la segmentation assistée par marqueurs, visent à séparer l'image en segments uniformes[3, 56, 57]

Les méthodes de segmentation par apprentissage automatique utilisent des techniques avancées d'apprentissage pour améliorer la segmentation comme le regroupement flou C-means, le regroupement k-means et le regroupement hiérarchique. Ces méthodes regroupent les pixels similaires sans étiquettes préalables.[3, 56]

Les méthodes de segmentation par apprentissage profond a transformé radicalement la segmentation d'images. Parmi ces techniques, des architectures comme SegNet, U-Net et les réseaux de neurones convolutifs entièrement connectés (FCN). Ces modèles possèdent la faculté d'assimiler des représentations complexes des données, facilitant ainsi une amélioration significative de la précision dans la segmentation[55, 56].

Les différentes méthodes de segmentation, qu'elles soient classiques, basées sur l'apprentissage automatique ou profond, offrent des approches complémentaires pour améliorer la détection et la classification des anomalies dans les mammographies, soutenant ainsi les radiologues dans leur travail et facilitant la prise de décision clinique.

3.4.3. Classification des anomalies

La classification représente l'étape ultime des systèmes DAO et vise à attribuer des catégories aux anomalies détectées pour aider au diagnostic final. Cette étape est cruciale pour distinguer les anomalies bénignes des anomalies malignes, permettant ainsi aux radiologues de prioriser les cas nécessitant une attention immédiate. Les principales tâches de cette phase incluent l'extraction des caractéristiques ainsi que la classification elle-même[51, 58].

L'extraction des caractéristiques constitue une étape cruciale dans les systèmes reposant sur des algorithmes d'apprentissage automatique. Cette étape implique l'examen des formes, des textures, et des densités des tissus segmentés afin de dégager des données pertinentes. On emploie des descripteurs de caractéristiques pour saisir ces éléments, aidant ainsi à la classification future. Cette exploration détaillée contribue à une meilleure compréhension des caractéristiques des anomalies identifiées et fournit des informations cruciales pour les algorithmes de classification. Toutefois, avec les techniques d'apprentissage profond, l'étape d'extraction des caractéristiques est souvent intégrée et implicite au sein du modèle lui-même[51].

La classification utilise des algorithmes avancés d'apprentissage automatique et profond pour catégoriser les anomalies en tant que bénignes ou malignes. Dans le cadre des techniques d'apprentissage automatique, des modèles prédictifs tels que SVM et les forêts aléatoires sont couramment utilisés pour effectuer des classifications précises sur la base des caractéristiques extraites. Ces modèles apprennent à partir de données d'entraînement pour prédire les catégories des nouvelles données. Avec l'essor d'apprentissage profond, les CNNs apprennent automatiquement les caractéristiques discriminantes des anomalies pendant le processus d'entraînement. Des modèles d'apprentissage profond tels que ResNet, DenseNet, MobileNet et InceptionNet ont montré des performances exceptionnelles dans classification des anomalies mammaires, ces modèles excellent dans le traitement de quantités massives de données et dans l'identification de configurations complexes présentes dans les images[59]. Ces techniques avancées permettent non seulement de classer les anomalies avec une grande précision, mais aussi d'évaluer la probabilité de malignité, ce qui aide les radiologues à prendre des décisions avisées et à donner la priorité aux cas les plus urgents et critiques[51]. Récemment, les mécanismes d'attention ont été intégrés aux modèles de DL pour améliorer encore la performance de la classification. Les techniques basées sur l'attention, telles que les réseaux d'attention et les mécanismes d'attention auto-régressive, permettent aux modèles de se

concentrer sur les régions les plus pertinentes des images mammographiques. Ces mécanismes renforcent la capacité du modèle à distinguer les anomalies importantes des tissus normaux, en modulant l'apport des diverses zones de l'image. Des architectures telles que les Transformers, ainsi que l'intégration de modules d'attention dans les CNN, comme les modules d'attention sélective et les modèles fondés sur le Vision Transformer (ViT), ont montré des performances accrues dans la classification des images médicales en se focalisant sur les caractéristiques critiques nécessaires pour un diagnostic précis [60].

En résumé, que ce soit à travers l'extraction directe des caractéristiques par les méthodes d'apprentissage automatique, l'apprentissage intrinsèque des caractéristiques via les techniques d'apprentissage profond ou l'amélioration des performances par les mécanismes d'attention, la phase de classification demeure cruciale pour la précision et l'efficacité des systèmes DAO dédiés au cancer du sein.

4. Revue de la Littérature du DAO du Cancer du Sein

Ces dernières années, Les systèmes DAO ont intégré des technologies avancées de traitement d'images médicales ainsi que des approches basées sur IA, offrant une aide précieuse aux radiologues. Ce qui rend les systèmes DAO si efficaces, c'est leur capacité à automatiser des étapes clés du processus de diagnostic. Chaque phase du processus est déterminante pour la fiabilité globale du système, et de nombreux efforts ont été déployés pour perfectionner ces systèmes afin d'améliorer leur précision à chaque étape[61].

Cette section a pour objectif de passer en revue les recherches existantes sur les systèmes DAO, qui sont devenus des outils indispensables pour optimiser le diagnostic du cancer du sein. Au fil du temps, ces systèmes ont intégré des technologies sophistiquées de traitement d'images et des méthodes fondées sur l'IA, améliorant ainsi la détection et la classification des anomalies dans les mammographies. Parmi les étapes clés automatisées par ces systèmes, cela inclut la détection des anomalies, la segmentation des masses, ainsi que la classification des lésions en catégories bénignes ou malignes. Ainsi que la validation des résultats. Chaque phase contribue de manière cruciale à la performance globale du système, et de nombreux efforts ont été réalisés pour perfectionner la précision à tous les niveaux[5, 51].

Dans cette section, nous examinerons les travaux existants en mettant en avant les contributions scientifiques majeures et les tendances actuelles. Nous revisiterons les différentes étapes du processus abordées dans le chapitre précédent. Cette revue nous permettra de mieux comprendre l'état actuel des recherches dans ce domaine et d'identifier les points à améliorer afin de situer notre propre contribution dans ce contexte.

Nous porterons une attention particulière aux méthodes basées sur l'intelligence artificielle, qui ont récemment transformé les systèmes DAO grâce aux réseaux de neurones profonds et à l'apprentissage automatique. Toutefois, les méthodes traditionnelles, ayant joué un rôle significatif dans le développement des systèmes DAO, ne seront pas négligées. En explorant ces travaux, nous mettrons en lumière les progrès réalisés, tout en identifiant les défis persistants, particulièrement en termes de précision, de fiabilité et de l'incorporation des systèmes DAO dans le diagnostic clinique du cancer du sein.

4.1. Travaux sur la Détection des Masses dans les Mammographies

Repérer les masses sur les images mammographiques est un élément clé dans l'opération des systèmes DAO appliqués au cancer du sein. Les masses mammaires, qui peuvent indiquer une présence cancéreuse, se manifestent sous diverses formes et tailles, ce qui complique leur détection automatique. Cette sous-section passe en revue les approches classiques et les méthodes modernes dédiées spécifiquement à la détection des masses, ainsi que les défis et avancées dans ce domaine.

4.1.1. Méthodes Traditionnel & Basées sur l'Apprentissage Automatique

Les approches d'apprentissage automatique jouent un rôle clé dans la détection des masses dans les mammographies, avec une forte dépendance aux SVM[62, 63]. En 2015, Une équipe de chercheurs[63] a atteint les meilleures performances avec une précision de 81,4%, en utilisant 474 mammographies numérisées. Leur algorithme suivait cinq étapes principales : un prétraitement à l'aide d'une amélioration morphologique, une segmentation basée sur une méthode de clustering itératif, une présélection des régions suspectes à l'aide d'une classification par règles, un raffinement des contours des lésions potentielles grâce à l'évolution des contours régularisés par distance, une réduction des faux positifs via l'extraction de caractéristiques, suivie par une classification par SVM. Une autre étude prometteuse, menée par le chercheur Mohanty en 2019[64], a utilisé deux ensembles de données en accès libre (DDSM et MIAS) avec un total de 1814 mammographies numérisées. Le modèle a d'abord utilisé la transformation de Tchebichef afin d'obtenir les propriétés des régions d'intérêt, En appliquant une combinaison d'analyse en composantes principales (PCA) et d'analyse discriminante linéaire (LDA), nous avons réussi à diminuer la dimension de chaque vecteur de caractéristiques. Enfin, les caractéristiques réduites ont été classifiées à l'aide d'un réseau de neurones à apprentissage extrême (ELM), avec un échantillonnage en validation croisée stratifiée en cinq plis pour chaque image, afin d'éviter le sur-apprentissage. Par rapport à travail de Dheeba[65] en 2014, qui ont utilisé un ensemble de données restreint avec 216 mammographies numérisées, Mohanty a atteint une précision de 100% et 99,5 % sur chaque ensemble de données (contre 96,7 % pour Dheeba). D'autres classificateurs, tels que LDA, KNN, Naive Bayes , AdaBoost, et les forêts aléatoires [66–70], ont également été utilisés pour la détection des masses. Plusieurs travaux ont tous exploité le même ensemble de données DDSM[67, 68]. La performance de classification la plus élevée a été atteinte avec une sensibilité de 90,3 % et une AUC de 0,98, en utilisant 358 mammographies numérisées et une validation par maintien des données pour chaque ROI[66]. Leur méthode s'appuyait sur l'exploitation de caractéristiques de texture locale et discrète pour détecter les masses de manière efficace. Bien que l'algorithme proposé par Chakraborty, fondé sur un seuillage d'intensité itératif couplé à une croissance radiale des régions, ait obtenu des performances relativement modestes (85 % de sensibilité et 1,4 faux positif par image) [68]. D'autre part, Dhahbi (2015) [67] ainsi qu'Eltoukhy (2018)[69] ont utilisé des bases de données accessibles publiquement pour évaluer leurs méthodes : MIAS pour les deux études, avec l'ajout de DDSM pour Dhahbi et IRMA pour Eltoukhy . En particulier, Les résultats d'Eltoukhy sont encourageants, avec une précision de 93,3 % sur la base IRMA et 90,6 % sur la base MIAS, en recourant à l'extraction de caractéristiques basée sur la transformation curvelet et la théorie des moments, dans un cadre de validation croisée à 10 plis. De leur côté, Dhahbi a atteint une précision de 91,3 % en exploitant des caractéristiques pertinentes, notamment les moments de Gauss-Hermite exacts, avec une validation croisée fondée sur l'exclusion d'une image à chaque itération.

Cet ensemble conséquent de recherches sur l'emploi de méthodes d'apprentissage automatique fondées sur les caractéristiques a joué un rôle significatif dans l'augmentation de l'efficacité des systèmes DAO pour la détection des masses dans les mammographies, tout en laissant subsister certains défis bien que certains défis demeurent. Les méthodes traditionnelles de détection des masses, bien qu'efficaces dans certains cas, souffrent de plusieurs limitations. Tout d'abord, ces techniques dépendent fortement de l'étape d'extraction de caractéristiques, qui nécessite souvent une expertise manuelle pour sélectionner les attributs pertinents des images. De plus, elles sont influencées par les différences dans les mammographies liées à la qualité, au contraste et à la forme des masses. Les résultats peuvent être très différents selon les bases de données utilisées et les méthodes de validation, ce qui limite leur capacité à s'appliquer dans des contextes cliniques réels.

Bien que ces méthodes traditionnelles aient joué un rôle fondamental dans les premières recherches sur la détection des masses, elles ont progressivement été remplacées par les approches basées sur l'apprentissage profond, qui apportent une plus grande flexibilité et robustesse dans divers contextes. En s'appuyant sur des réseaux de neurones profonds capables d'apprendre directement à partir des images, ces nouvelles méthodes diminuent la nécessité d'une extraction manuelle des caractéristiques tout en améliorant les performances dans des situations médicales plus complexes. D'autres méthodes de détection des masses basées sur les apprentissages automatiques sont exposées dans le Tableau II.1

4.1.2. Méthodes Basées sur l'Apprentissage profond

Récemment, l'apprentissage profond a gagné en popularité pour la détection automatique des anomalies mammaires, en particulier grâce aux réseaux neuronaux profonds et aux CNN[5]. L'une des premières études marquantes dans ce domaine a été menée par Dhungel en 2015[71], qui ont appliqué le DL à la détection des masses. Pour cette étude, deux bases de données en accès libre ont été utilisées, DDSM-BCDR et INbreast, contenant à la fois des mammographies numérisées et numériques.

Afin d'augmenter la taille de l'échantillon, une augmentation des données a également été réalisée. L'approche proposée par Dhungel et son équipe se déroulait en plusieurs étapes. Tout d'abord, un réseau de croyances profondes multi-échelle (Deep Belief Network) était utilisé pour sélectionner les régions suspectes. Ensuite, un système à deux niveaux basés sur des CNN procédait à un traitement plus approfondi de ces régions. Enfin, les régions ayant passé cette cascade de classificateurs RF (Random Forest) étaient fusionnées à l'aide d'une analyse des composants connectés. Pour la validation croisée, une validation en 5 plis a été appliquée pour chaque patient, obtenant une sensibilité de 96 % et 75 % sur les deux bases de données respectivement, avec 4,8 et 1,2 faux positifs par image (FPi). D'autres études ont également exploité les bases de données en accès libre. Par exemple, Al-Masni en 2018 a obtenu des résultats remarquablement précis en exploitant l'ensemble de données DDSM. Ce succès est dû à l'élargissement du volume de données ainsi qu'à l'application d'une technique d'apprentissage profond basée sur les régions, intégrant un CNN reposant sur la méthode "You Only Look Once" (YOLO)[72]. Pour éviter les biais entre l'entraînement et le test, les paramètres du système ont été optimisés uniquement sur le jeu d'entraînement, tandis que les performances finales ont été évaluées sur le jeu de test. Les jeux d'entraînement et de test ont été définis en utilisant une validation croisée en 5 plis, mais appliquée par image plutôt que par patient. Des modèles pré-entraînés ont également été utilisés avec un succès modéré. Jung en 2018 [73] Ils ont fusionné les deux ensembles de données INbreast & GURO, qui est plus restreinte, pour constituer un ensemble total de 632 mammographies numériques.

Tableau II. 1: Les techniques de détection des masses fondées sur l'apprentissage automatique

'Réf	Base de données	Type d'images	Ensemble de données	Classifieur	Méthode de validation	Résultats
[66]	Accès libre (DDSM)	Numérisées	358 images	LDA	Validation par maintien (par ROI)	SEN: 90,3 %, AUC: 0,98
[65]	Restreint	Numérisées	216 images	PSOWNN	1064 ROIs pour l'entraînement (par ROI)	ACC: 93,7 %, SEN/SPEC: 94,2 / 92,1 %, AUC: 0,97
[63]	Accès libre (DDSM)	Numérisées	474 images	SVM	66%-33% (par ROI)	ACC : 81,4 %, SEN/SPEC: 93,4 / 78,2 %,
[62]	Accès libre (DDSM)	Numérisées	599 images	SVM	499-100 (par image)	ACC: 83,5 %, SEN/SPEC: 92,3 / 82,2 %, AUC: 0,80
[67]	Accès libre (mini-MIAS)	Numérisées	252 images	k-NN	Validation par exclusion d'un exemple (par image)	ACC: 91,3 %, AUC: 0,99
[68]	Accès libre (DDSM)	Numérisées	1300 images	NB	Validation croisée à 10 plis (par patient)	SEN: 85 %
[69]	Accès libre (IRMA, MIAS)	Numérisées	1516 ROIs / 256 ROIs	AdaBoost	Validation croisée à 10 plis	ACC: 93,3 % (IRMA), 90,6 % (MIAS), AUC : 0,96 (IRMA), 0,89 (MIAS)
[70]	Accès libre (DDSM)	Numérisées	10168 ROIs	RF	Validation croisée stratifiée à 10 plis	ACC: 81,1 %
[64]	Accès libre (MIAS, DDSM)	Numérisées	314 images / 1500 images	IGWO-ELM	Validation croisée stratifiée à 5 plis (par image)	ACC: 100 % (MIAS), 99,5 % (DDSM), AUC: 1 (MIAS), 0,99 (DDSM)

Ensuite, Ils ont mis en œuvre un modèle de détection des masses basé sur RetinaNet, en y incorporant des méthodes d'augmentation de données. Une validation croisée en 5 plis a été appliquée par image, et les résultats ont montré une sensibilité de 98 % avec 1,3 FPI. Ribli en 2018[74] ont proposé un système DAO basé sur l'un des cadres de détection d'objets les plus performants Faster R-CNN. Un total de 3877 mammographies, à la fois numérisées et numériques, ont été recueillies à partir de deux bases de données publiques (DDSM et INbreast) ainsi que d'une base de données privée. L'algorithme a été entraîné en utilisant à la fois DDSM et la base restreinte, puis testé sur INbreast, atteignant des résultats prometteurs avec une aire sous la courbe (AUC) de 0,95.

Les études existantes montrent que l'apprentissage profond, notamment les CNN, a permis de franchir une étape décisive dans la détection des anomalies mammaires. Alors que les méthodes

d'apprentissage automatique basées sur les caractéristiques ont ouvert la voie, les modèles basés sur l'apprentissage profond démontrent actuellement une amélioration considérable en ce qui concerne leur précision, leur sensibilité, ainsi que leur capacité à minimiser le taux de faux positifs. Cependant, malgré ces résultats prometteurs, leur adoption clinique généralisée est encore freinée par plusieurs facteurs, Parmi les défis majeurs, on compte la disponibilité de données annotées, la variabilité inhérente aux mammographies, ainsi que l'impératif d'optimiser les architectures des modèles pour une application dans des contextes pratiques. Concernant cette problématique, les orientations futures de la recherche devraient prioriser la diminution des biais associés aux données, le perfectionnement des procédures de validation croisée, ainsi que l'investigation de techniques innovantes d'augmentation de données afin d'accroître la robustesse et la faculté de généralisation des modèles à différents contextes cliniques. Le tableau II.2 illustre des travaux de détection des masses qui reposent sur des approches d'apprentissage profond.

Tableau II. 2: Synthèse des Études sur la Détection des Masses utilisant des approches basées apprentissage profond

Référence	Base de données	Type d'images	Augmentation des données	Classificateur	Méthode de validation
[71]	DDSM-BCDR, INbreast	Les deux	OUI	CNN (cascade de DL et RF)	Validation croisée 5 plis (par patient)
[75]	INbreast	Numérique	OUI	CNN	Validation croisée 5 plis (par patient)
[76]	MIAS	Numérisée	NON	CNN	70%–30% (par image)
[74]	DDSM, INbreast	Les deux	OUI	R-CNN	Entraîné sur DDSM et restreint tester sur INbreast (par image)
[73]	INbreast	Numérique	OUI	CNN (RetinaNet)	Validation croisée 5 plis (par patient)
[72]	DDSM	Numérisée	OUI	CNN (YOLO)	Validation croisée 5 plis (par image)
[77]	CBIS-DDSM, INbreast	Les deux	OUI	CNN	85%–15% stratifié (par patient)
[78]	INbreast	Numérique	OUI	CNN (YOLO-V3)	Validation croisée 5 plis (par image)

4.2. Travaux sur la Segmentation des Masses dans les Mammographies

La segmentation précise des masses mammaires est une étape clé dans la détection précoce du cancer du sein, comme indiqué précédemment. Elle permet d'isoler les régions d'intérêt dans les mammographies, facilitant ainsi l'identification et l'analyse des lésions. Au fil des années, diverses approches ont été développées pour améliorer la précision de cette segmentation. Ces approches se divisent principalement en deux catégories : Les méthodes traditionnelles, s'appuyant sur des procédés classiques de traitement d'images, se différencient des stratégies contemporaines qui bénéficient des avancées significatives dans les domaines de

l'apprentissage automatique. Au départ, nous mettrons l'accent sur les méthodes traditionnelles de segmentation, qui ont établi les fondations des techniques plus avancées. Bien que ces méthodes aient été largement remplacées par des modèles d'apprentissage profond Dans les pratiques actuelles, elles maintiennent leur importance dans le domaine du traitement des images médicales. Nous analyserons diverses méthodes de segmentation classique, telles que le seuillage, les contours actifs et les stratégies basées sur les régions, en nous concentrant sur les études pertinentes qui ont contribué à leur développement.

4.2.1. Méthodes de Segmentation Classique

Plusieurs recherches ont conduit au développement de méthodes permettant la détection précoce des lésions cancéreuses mammaires, qui ont été appliquées pour segmenter les masses à partir d'images associées au cancer du sein. Les techniques élaborées comprennent le seuillage, l'application de modèles de contours actifs, et la méthode de croissance de régions[79]. La segmentation traditionnelle utilise les valeurs de pixels dans une image et se catégorise en trois types principaux : la segmentation axée sur les régions, celle basée sur les contours, ainsi que la méthode de seuillage. Ce type de segmentation divise une image en régions distinctes, chacune ayant des caractéristiques spécifiques. De plus, les méthodes de segmentation classique constituent une première génération de techniques reposant sur des approches de bas niveau, nécessitant peu d'informations[80].

4.2.1.1. La segmentation basée sur les régions

Berber [81] a élaboré une technique de segmentation des contours des masses mammaires dans les mammographies numériques, se servant de la méthode reconnue de croissance de régions amorcée par des points de départ spécifiques. Cette approche a également été appliquée à un ensemble de 260 masses extraites de la base de données mammographique de Dokuz Eylul (DEMS), où elle a réalisé un taux de précision de 95,06 %.

Petrick [82] a développé une méthode combinant l'amélioration adaptative et la mise en œuvre de la technique de segmentation par expansion de régions sur les masses mammaires détectées dans les images mammographiques. Les images ont été optimisées grâce à un contraste pondéré par la densité, tandis que le bruit a été atténué à l'aide d'un filtre gaussien. Cette méthode a été testée sur 253 mammographies provenant de l'Hôpital de l'Université du Michigan (UMH), atteignant une précision de segmentation de 98,0 %.

Une recherche[83] a exploré l'application d'une méthode de segmentation par croissance de régions, spécialement optimisée pour l'identification automatique des masses dans les mammographies. Dans ce cadre, des attributs texturaux, tels que la matrice de cooccurrence des niveaux de gris et la matrice de longueur des séquences, ont été dérivés des images segmentées pour fournir les données d'entrée à un réseau de neurones de type feedforward. L'efficacité de cette approche a été validée sur un corpus de 300 images mammographiques issues de la base de données DDSM, en utilisant un filtre gaussien pour réduire le bruit présent dans les images. Cette étude a révélé une sensibilité de 98,1 % et une spécificité de 97,8 %, avec une performance de segmentation estimée à 90,0 %, mesurée par l'indice de Jaccard.

Soukaina [84] a conçu une méthode pour la segmentation des tumeurs mammaires et l'élimination du muscle pectoral, utilisant des modèles de Markov cachés conjointement avec la méthode de croissance de régions. L'objectif de cette méthode était de distinguer les muscles

pectoraux dans les images mammographiques tout en extrayant en parallèle les caractéristiques des tumeurs mammaires. La méthode se déroule en deux phases principales : (a) l'application du seuillage d'Otsu et (b) la classification des images via l'algorithme k-means. Les images mammographiques étudiées ont été obtenues à partir de la base de données MIAS. D'après les résultats obtenus, cette méthode a démontré une précision de 91,92 % et un taux d'erreur de 8,07 %.

4.2.1.2. Segmentation des Mammographies Par Techniques de Seuillage

Une recherche a suggéré l'emploi de la technique de segmentation par seuillage pour détecter les masses dans les mammographies [85]. Cette technique détecte une région de masse en employant un seuillage morphologique. L'évaluation de cette méthode a été conduite sur un ensemble de 55 mammographies issues de la base de données mini-MIAS. Le prétraitement des images mammographiques a été réalisé à l'aide d'un filtre médian et à une égalisation d'histogramme adaptative à contraste limité. Les résultats ont révélé une précision de segmentation de 94,54 %, accompagnée d'un taux de faux positifs de 5,45 %.

Singh et Veenadhari [86] ont développé une méthode de segmentation du cancer du sein qui utilise un seuillage global combiné à la fusion de régions. Pour éliminer le bruit gaussien, un filtrage de Wiener a été appliqué, et la normalisation de l'image a été réalisée par réduction de l'histogramme. Le seuillage global, basé sur la méthode d'Otsu, a ensuite été utilisé pour segmenter les masses présentes dans le ROI. Cette méthode a été mise en œuvre et testée dans un environnement MATLAB sur 50 images de mammographie, ce qui a permis d'obtenir le ROI. Les résultats démontrés ont montré une précision atteignant 82,0 %, accompagnée d'un taux d'erreur s'élevant à 18,0 %.

4.2.1.3. Segmentation Basée sur la Technique des Contours

Une technique totalement automatisée pour la délimitation des contours des seins et des muscles pectoraux sur les mammographies a été suggérée [87]. Le contour du muscle pectoral a été identifié en utilisant la technique de détection de contours basée sur la méthode de Canny, tandis que le bruit a été supprimé à l'aide d'un filtre médian combiné à un filtre de diffusion anisotrope. Cinq caractéristiques ont été extraites pour définir le contour du sein. Un total de 322, 208 et 100 images mammographiques ont été rassemblées respectivement à partir des bases de données MIAS, INbreast et BCDR. L'approche utilisée a obtenu des coefficients de similarité de Dice de 98,8 % et 97,8 % pour MIAS, de 98,9 % et 89,6 % pour INbreast, et de 99,2 % et 91,9 % pour BCDR.

Chakraborty [88] a proposé une méthode automatique pour détecter les contours des masses mammaires dans les images mammographiques, avec pour but d'identifier et de localiser les discontinuités dans ces images. Cette méthode a été évaluée sur un ensemble de 160 images mammographiques provenant de la base de données mini-MIAS, où le bruit a été réduit à l'aide d'un filtre bidimensionnel. Les résultats obtenus indiquent que cette méthode a atteint une précision de segmentation de 92,5 %.

Le Tableau II.3 fournit un récapitulatif des différentes recherches menées sur la segmentation des masses mammaires à l'aide de méthodes conventionnelles, soulignant la variété des techniques employées utilisées et les performances atteintes dans ce secteur.

Tableau II. 3: Synthèse des Études sur la Segmentation des Masses utilisant des Method Classique

Réf	Catégorie	Technique	Filtre	Ensemble de données	Résultat
[84]	Méthode de région	Modèles de Markov cachés et croissance de régions	-	MIAS	91,92 % précision 8,07 % Taux erreur
[89]		Watershed combine avec k-NN	Sober	MIAS	83,33 % précision
[83]		Croissance de régions	Filtre Gaussien	DDSM	90,0 % précision
[90]		Watershed	-	MIAS	94,0 % de détection fausse et 18,0 % de détection positive
[91]	Méthode de seuillage	Otsu	Morphologique	WHC et DDSM	100,0 % de précision pour WHC et 91,30 % pour DDSM
[85]		Otsu	Clahe	MIAS	96,0 % de précision
[92]		Histogramme et détection de contours	Filtre Gaussien	MIAS et EPIC	98,8 % de précision (MIAS) et 91,5 % (EPIC)
[93]		Seuillage global et local adaptatif	-	MIAS	91,3 % de sensibilité et 0,71 % de faux positifs
[94]	Méthode de contour	Coupe dynamique par graphe	-	MIAS et DDSM	98,88 % de sensibilité, 98,89 % de spécificité, et 93,0 % pour les valeurs négatives
[87]		Détection des contours de Canny	Filtre Médian	MIAS, INbreast, et BCDR	98,8 % pour Dice, 97,8 % pour MIAS, 98,9 % pour le contour, 89,6 % pour INbreast, et 99,2 % pour le contour, 91,9 % pour BCDR
[95]		Cascade Gabor	-	UHGL	100,0 % de sensibilité et 3,4 % de faux positifs

4.2.2. Méthodes de Segmentation Basées sur l'Apprentissage Profond

L'émergence de l'apprentissage profond a transformé la segmentation des masses mammaires dans les images mammographiques, offrant des performances significativement meilleures par rapport aux méthodes traditionnelles. En raison de l'aptitude des CNN à identifier automatiquement des attributs complexes dans les images, ces techniques assurent une précision et une robustesse améliorées dans l'identification et la segmentation des tumeurs mammaires. Les travaux de recherche récents ont adopté des architectures avancées, incluant U-Net, YOLO, et des modèles qui utilisent des réseaux neuronaux récurrents, dans le but d'optimiser la performance de la segmentation. Ces méthodologies ont démontré leur potentiel

en affichant des résultats encourageants sur plusieurs bases de données, notamment MIAS, INbreast et DDSM.

Tableau II. 4:Les méthodes de segmentation basée apprentissage profond

Réf	Technique	Filtre	Base de données	Résultat
[96]	RU-Net	Filtre cLare	INbreast et DDSM-BCRP	98,0 % de Dice, 94,0% d'IOU, et 98,0 % de précision
[97]	U-Net	Filtre Laplace	DDSM	97,80 % de Dice et 98,50 % de F1-score
[98]	AUNet	-	INbreast et DDSM	81,80 % de Dice pour DDSM et 79,10 % d'Indice de Similarité (DI) pour INbreast
[99]	CRU-Net	-	INbreast et DDSM	93,66 % de Dice pour INbreast et 93,32 % pour DDSM
[100]	U-Net	-	DDSM	79,39 % de Dice, AUC de 86,40 %, et 85,95 % de précision
[101]	U-Net	-	DDSM	88,0 % de précision
[102]	U-Net	-	MIAS et DDSM	98,87 % de Dice, AUC de 98,88 %, et F1-score de 97,99 %
[103]	cGAN	Filtre Médian	INbreast	88,0 % de Dice, Jacard de 78,0 %, et 98,0 % de précision
[104]	cGAN	Filtre Morphologique	DDSM	94,0 % de Dice et IOU de 87,0 %

Al-antari [53] a développé un système intégré de diagnostic assisté par ordinateur pour la détection, la segmentation et la classification des masses mammaires, utilisant l'apprentissage profond et s'appuyant sur l'architecture YOLO. Cette approche régionale d'apprentissage profond a été conçue pour segmenter les masses à l'aide d'un réseau convolutionnel à pleine résolution (FrCN). Cette technique a été testée avec la base de données INbreast, révélant un taux de succès dans l'identification des masses de 98,96 % et un coefficient de corrélation de Matthews (MCC) de 97,62 %, avec un score F1 de 99,24 %. Pour ce qui est de l'exactitude de la segmentation des masses, grâce à l'utilisation de FrCN, elle s'est élevée à 92,97 %, avec un MCC de 85,93 %, une similarité de Dice de 92,69 % et une similarité de Jaccard de 86,37 %. De plus, la classification après la détection et la segmentation des masses en employant un CNN a indiqué une précision de 95,64 % et une AUC de 94,78 %.

Ravitha [105] a conçu un U-Net profondément supervisé pour la segmentation des masses dans les mammographies numériques, désigné sous le nom de DS-U-Net. La méthode a été évaluée en utilisant les ensembles de données DDSM et INbreast, avec une amélioration du contraste des images grâce au filtre cLare. Les expériences ont été menées en deux groupes : l'un avec prétraitement des images et l'autre sans. Les résultats ont démontré que les expériences intégrant un prétraitement ont surpassé celles sans. Cette technique a affiché des résultats remarquables, incluant un indice de Dice de 82,70 %, un coefficient de Jaccard de 85,70 %, une précision de 99,70 %, une sensibilité de 83,10 %, et une spécificité de 99,80 %. Ces résultats ont été significativement améliorés grâce à un prétraitement efficace

Saffari [103] a proposé une segmentation entièrement automatisée de la densité mammaire basée sur des réseaux adversariaux génératifs conditionnels (cGAN) et une classification utilisant l'apprentissage profond. L'approche basée sur le réseau cGAN a été mise en œuvre pour segmenter les tissus denses dans les images de mammographie. Cette technique a été évaluée sur une collection de 410 images provenant de 115 patients, obtenues de la base de données INbreast. Un filtre médian a été employé pour diminuer le bruit dans les images. Les performances de segmentation réalisées à l'aide de cGAN ont indiqué une précision de 98,0 %.

Salama [102] a développé un modèle d'apprentissage profond dédié à la segmentation et à la classification des images mammographiques. Ce modèle repose sur une version modifiée de l'architecture U-Net pour segmenter la zone mammaire dans les images de mammographie. L'évaluation a été réalisée sur trois ensembles de données : MIAS, DDSM et CBIS-DDSM. Les performances du modèle suggéré révèlent une exactitude de 98,87 %, une précision de 98,79 %, et une AUC de 98,88 %.

Une étude notable a été menée sur 107 mammographies provenant de la base de données INbreast, qui ont révélé un total de 112 masses mammaires. Les chercheurs ont utilisé YOLO pour la détection des masses mammaires et ont proposé une augmentation du jeu de données en effectuant une rotation de chaque image huit fois, générant ainsi 896 images supplémentaires. Afin d'évaluer le modèle développé, ils ont réalisé des validations croisées à quatre volets. Les auteurs rapportent que les résultats de détection sur l'ensemble des tests ont révélé une précision moyenne de 98,96 % [106].

Le Tableau II.4 Le Tableau II.4 offre un aperçu des études sur la segmentation des masses mammaires via l'apprentissage profond, soulignant les méthodes, résultats, et bases de données utilisées.

4.3. Travaux sur la Classification des Masses

La catégorisation automatique des irrégularités, en particulier la différenciation des masses mammaires en catégories bénignes ou malignes, a fait l'objet de nombreuses recherches. Toutefois, comme pour d'autres tâches dans les systèmes DAO, comparer les diverses méthodes s'avère souvent complexe en raison des différences notables dans les stratégies de validation et d'évaluation utilisées. Afin de mieux comprendre ces techniques, les études existantes peuvent être classées en deux grandes catégories : celles basées sur les méthodes d'apprentissage automatique et celles utilisant des techniques d'apprentissage profond [47, 51, 107].

4.3.1. Techniques Basées sur apprentissage automatique :

Les techniques basées sur l'apprentissage automatique traditionnel, telles que les SVM[108–110], les ANN [111], et les perceptrons multicouches (MLP)[112], ainsi que les méthodes d'ensembles [113], ont été largement utilisées pour classifier les masses mammaires en lésions bénignes ou malignes. Ces algorithmes reposent sur le prélèvement précis de caractéristiques directement issues des images, en s'appuyant fréquemment sur des bases de données qui sont librement accessibles.

Par exemple une étude[108] propose d'extraire sept caractéristiques texturales via la méthode GLCM appliquée à des sous-images afin d'améliorer la performance de classification. En parallèle, des méthodes hybrides, telles que Wavelet-CT1 et ST-GLCM, ont été développées, Intégrant divers types de caractéristiques afin d'améliorer la détection des masses, résultant en des performances améliorées sur les bases de données DDSM et MIAS.

Certaines recherches se sont spécifiquement penchées en utilisant des méthodes spécifiques d'extraction de caractéristiques, comme l'emploi de la transformée de Hough [109] pour isoler des formes particulières dans les mammographies a montré une amélioration de la précision du diagnostic, notamment en couplant cette méthode avec un classifieur SVM. Ces approches permettent une meilleure détection des masses, essentielles pour un diagnostic précoce du cancer du sein.

En plus, une méthode de classification innovante basée sur la machine d'apprentissage extrême (ELM) a été proposée[111] pour identifier des masses mammaires. Après le prétraitement et la segmentation des images, le choix des caractéristiques est réalisé en employant une combinaison de machines à vecteurs de support et de machines à apprentissage extrême , ce qui facilite l'optimisation du sous-ensemble de vecteurs de caractéristiques employés pour différencier les masses bénignes des malignes. Cette méthode se distingue par une meilleure précision, atteignant 96,02 %, et un temps d'entraînement réduit, surpassant les performances des méthodes comme SVM et PSO-SVM[111].

Dans un autre travail, un système DAO utilisant la mammographie numérique avec contraste (CEDM) a été proposé pour classifier les masses mammaires en bénignes ou malignes. Cette méthode est fondée sur l'extraction de caractéristiques quantitatives associées à la forme et à l'hétérogénéité des masses, à partir d'images à faible énergie (LE) et d'images obtenues par soustraction à double énergie (DES). Un ensemble de 109 caractéristiques a été calculé, puis un classificateur basé sur des perceptrons multicouches, intégré à une évaluation par sous-ensemble de caractéristiques corrélées et une validation croisée, a été employé pour la classification. L'intégration des résultats de segmentation optimisés a significativement amélioré les performances de classification, avec une augmentation de l'AUC à 0,8477, démontrant ainsi l'efficacité du classificateur appliqué aux images 'CEDM'[112].

Tableau II. 5: Les méthodes de classification basée apprentissage automatique

Références	Base de données	Type d'images	Classifieur	Résultats
[114]	Disponible (MIAS) 322 images	Numérisé	MLP	ACC : 96.4 ; AUC : 0.98
[111]	Disponible (MIAS, DDSM) 322/2620 images	Numérisé	NN (Machine d'apprentissage extrême)	ACC : 96 ; AUC : 0.97
[113]	Disponible (DDSM) 514 ROIs	Numérisé	Ensemble	AUC : 0.93
[110]	Disponible (DDSM) 1155 ROIs	Numérisé	SVM	ACC : 88.3 ; AUC : 0.88
[112]	Restreint 111 patients	Numérisé	MLP	ACC : 78.4 ; AUC : 0.85
[115]	Disponible (Mini-MIAS, DDSM) 55/240 images	Numérisé	Ensemble	ACC : 94.8 ; AUC : 0.96
[108]	Disponible (DDSM, MIAS) (1024/291) images	Numérisé	SVM	ACC : 98.7 ; AUC : 0.98
[116]	Disponible (DDSM) 794 ROIs	Numérisé	SVM	ACC : 90.2 ; AUC : 0.96

Une méthode innovante a été proposée pour convertir les contours 2D des masses mammaires en signatures 1D, ce qui permet une caractérisation plus détaillée des contours et de la régularité des masses. En segmentant ces signatures en sous-sections et en extrayant des descripteurs, notamment la pente quadratique moyenne (RMS), cette approche a été testée avec plusieurs classificateurs, notamment KNN, SVM et ANN. Le meilleur résultat a été obtenu avec le classificateur SVM, atteignant une précision de classification de 99,66 % sur la base DDSM, démontrant ainsi une capacité remarquable à différencier les masses bénignes des malignes[117].

Afin d'améliorer l'efficacité des systèmes DAO dans la classification des lésions mammaires, une méthode de classification par ensemble a été suggérée. L'innovation de cette approche

réside dans la combinaison de différentes représentations des caractéristiques et dans le rééchantillonnage des données pour créer des classificateurs plus diversifiés, ainsi que dans l'implémentation d'un mécanisme de sélection d'ensemble. Cette méthode, qui fonctionne aussi bien avec des classificateurs faibles que forts, a montré des performances supérieures aux réseaux de neurones et SVM traditionnels, avec une AUC de 0,932, confirmant ainsi son efficacité dans le domaine[113].

Une étude a été réalisée pour évaluer six approches d'extraction de caractéristiques directionnelles pour la classification des masses dans les mammographies numériques. Ces méthodes utilisent les filtres de Gabor pour extraire des caractéristiques texturales directionnelles, qui capturent les propriétés structurales des masses et des tissus normaux sous diverses orientations et fréquences. Ces stratégies ont été évaluées sur les ROIs extraites de la base de données MIAS., et un classificateur SVM pondéré par l'apprentissage par amélioration successive (SELwSVM) a été utilisé pour traiter les ensembles de données déséquilibrés[118].

Bien que les méthodes d'apprentissage automatique appliquées à la classification des masses mammaires aient montré des résultats prometteurs, plusieurs limites subsistent. Premièrement, la qualité des données employées pour entraîner les modèles représente souvent un facteur déterminant. La majorité des études se basent sur des bases de données accessibles publiquement telles que DDSM et MIAS, qui bien que largement utilisées, présentent certaines limites. Souvent, ces ensembles de données manquent de variété dans les images et ne capturent pas fidèlement l'hétérogénéité des populations dans des contextes cliniques réels. Le Tableau II.5 présente une synthèse des différentes études sur la classification des masses mammaires utilisant des méthodes basées sur l'apprentissage automatique.

Il en résulte une généralisation limitée des modèles lorsque ceux-ci sont appliqués à des images issues d'autres sources. Deuxièmement, les approches qui se basent sur l'extraction de caractéristiques explicites, telles que la méthode GLCM ou la transformée de Hough, dépendent des caractéristiques texturales et structurales définies manuellement, qui ne capturent pas toujours la complexité des masses mammaires, notamment dans les cas de mammographies denses. Ces approches peuvent également être compromises par des imprécisions liées à des changements dans la qualité des images ou à l'existence d'artefacts. En outre, certaines approches, telles que les ANN ou les MLP, peuvent nécessiter un temps d'entraînement considérable et sont souvent sensibles au problème de surapprentissage (Overfitting), en particulier lorsque les ensembles de données sont de petite taille ou déséquilibrés.

Même si les approches modernes, comme l'emploi des machines d'apprentissage extrême (ELM), Bien qu'ils aient montré des avancées significatives en termes de rapidité de calcul et d'efficacité, des obstacles persistent, notamment concernant la gestion optimale de bases de données à la fois massives et très déséquilibrées. Les stratégies visant à réduire les faux positifs, telles que celles utilisées dans les méthodes de classification des ROIs, requièrent aussi des améliorations. La différenciation entre les masses bénignes et malignes constitue particulièrement un défi lorsque les caractéristiques visuelles des masses se rapprochent fortement de celles des tissus sains, entraînant ainsi une augmentation des risques de faux positifs ou de faux négatifs. Le Tableau II.5 offre une synthèse des diverses recherches sur la classification des masses mammaires employant des méthodes d'apprentissage automatique. Dans la section suivante, nous discutons des travaux qui s'appuient sur les techniques d'apprentissage profond pour surmonter certaines des limites des approches classiques.

4.3.2. Techniques Basées sur l'Apprentissage profond :

L'apprentissage profond a transformé la classification des masses mammaires, surpassant les approches traditionnelles d'apprentissage automatique grâce à sa capacité à extraire automatiquement des caractéristiques complexes à partir des images médicales. Les techniques d'apprentissage profond, telles que CNN, l'apprentissage par transfert et les mécanismes d'attention, offrent une flexibilité et une robustesse accrues dans l'analyse des mammographies[47, 51, 119].

En outre, divers travaux récents ont souligné l'efficacité de ces algorithmes afin d'améliorer les performances de classification, surtout en termes de précision et de robustesse, spécialement lorsqu'ils sont utilisés sur d'importantes bases de données d'images médicales. En particulier, ces techniques permettent une meilleure différenciation entre les masses bénignes et malignes, contribuant ainsi à une réduction significative des faux positifs et à un diagnostic plus fiable[6, 28, 107].

L'une des premières utilisations notables des CNN dans ce contexte remonte à 2015, avec une étude qui a démontré une efficacité remarquable dans la classification des lésions mammaires, atteignant une AUC de 0,86 sur le jeu de données BCDR-F03, composé de 763 mammographies numérisées [120]. Ce travail pionnier a jeté les bases pour l'utilisation des CNN dans ce domaine et a ouvert la voie à des recherches plus avancées.

Dans une étude plus récente, une approche basée sur un CNN a été développée pour diagnostiquer le cancer du sein à partir de mammographies. En s'appuyant sur diverses architectures CNN, cette méthode permet d'apprendre efficacement des caractéristiques afin de différencier les cas normaux des cas pathologiques. Les résultats ont révélé une capacité de détection élevée, parvenant à des niveaux importants de précision, de sensibilité et de spécificité, ce qui valide l'efficacité de l'apprentissage profond dans les systèmes d'assistance au diagnostic clinique[121].

Toutefois, effectuer une comparaison directe la comparaison entre ces études se révèle difficile en raison de la diversité des jeux de données, des variétés d'images et des méthodes de validation utilisées. Par exemple, Wang (2018) a obtenu une précision de 85,2 % sur le jeu de données BCDR-F03 en utilisant un réseau MV-DNN avec une répartition des données spécifique pour l'entraînement, la validation et le test [122]. En parallèle, Gnanasekaran (2020) a utilisé un CNN à huit couches convolutionnelles pour classifier 1940 mammographies provenant des ensembles de données DDSM et MIAS, atteignant une précision impressionnante de 98,3 %, dépassant ainsi les performances des modèles pré-entraînés tels qu'AlexNet et VGG16 [123]

Une autre étude propose une méthode hybride combinant un modèle U-Net++ et des poids pré-entraînés du réseau Xception pour segmentation et classification des masses mammaires. En utilisant la technique de l'apprentissage par transfert, Cette technique a résulté en une AUC de 0,8188 et une précision de 76,19 %, mettant en lumière sa capacité à différencier efficacement entre les masses bénignes et malignes[124].

En outre, une recherche récente utilisant l'ensemble de données OPTIMAM a démontré l'efficacité des architectures DL, notamment RetinaNet, dans la détection des masses mammaires. En adoptant l'apprentissage par transfert ainsi que des stratégies de régularisation sans oublier d'équilibrage des classes, cette étude a donné des résultats prometteurs en matière de classification[125]. De plus, une approche basée sur le transfer learning avec un modèle

ResNet pré-entraîné sur un ensemble de données plus large a montré une précision de 93,15 % sur le jeu CBIS-DDSM, confirmant le potentiel de cette méthode dans l'amélioration du diagnostic assisté par ordinateur [126].

Tableau II. 6 : Les méthodes de classification basée apprentissage profond

Reference	Année	Method	Base de données	Nombre d'Images	Accuracy
[120]	2015	CNN	BCDR-F03	736	86%
[53]	2018	CNN	INbreast	410	95.6%
[122]	2018	Deep NN based on Multi-View data	BCDR-F03	736	85.2%
[72]	2018	FC-NN	DDSM	600	97%
[123]	2020	CNN	MIAS	322	98.3%
[127]	2020	CNN (InceptionResNet-V2)	DDSM, INbreast	600, 410	97.5%, 95.3%
[128]	2020	MobileNet, VGG, ResNet, Xception	CBIS-DDSM	1696	84.4%
[129]	2020	MobileNetV1, MobileNetV2	CBIS-DDSM	1696	74.5%
[130]	2020	DE-Ada*	CBIS-DDSM	-	87.05%
[131]	2020	GoogleNet	MIAS	68	88.24%
[132]	2021	DNN (Interpretable DL model)	Digital	1136	83%
[133]	2021	MobileNetV2, NasNet Mobile, MEWOM	CBIS-DDSM	1696	93.8%
[134]	2021	ResNet-18, (ICS-ELM)	MIAS	322	98.13%
[135]	2022	CNN classifier with different fine-tuning	DDSM	13128	98.96%
[136]	2023	VGG19-DF	DDSM	3500	81.71%

Dans les avancées récentes concernant la classification du cancer du sein, un nouveau modèle a été introduit pour optimiser l'analyse des mammographies. Ce modèle fusionne des caractéristiques obtenues via des CNN avec des caractéristiques extraites manuellement, telles que l'histogramme des gradients orientés (HOG) et le motif binaire local (LBP). Cette approche hybride tire parti des bénéfices des méthodes d'apprentissage profond et des techniques conventionnelles d'extraction de caractéristiques, résultant en une représentation des données plus solide. En ajoutant des caractéristiques manuelles, cette méthode ne se contente pas de renforcer la précision de la classification, mais elle intègre aussi l'expertise des spécialistes du domaine, renforçant ainsi l'interprétabilité et la transparence du modèle[137].

L'adoption de l'apprentissage profond pour la classification des masses mammaires a marqué une avancée significative dans le secteur du DAO. Grâce à l'efficacité des CNN et de l'apprentissage par transfert, qui facilitent l'extraction automatique de caractéristiques complexes, ces techniques dépassent les méthodes conventionnelles. Les résultats obtenus, en particulier en matière de précision, sensibilité et spécificité, illustrent la capacité supérieure des algorithmes contemporains à distinguer les masses bénignes des malignes. Bien que les résultats soient prometteurs, des défis subsistent, en particulier, le défi posé par l'évaluation comparative des études en raison des variations dans les jeux de données, les méthodes de validation et les méthodes utilisées. Ces variations compliquent l'évaluation uniforme des performances, mais elles illustrent aussi la diversité des approches adoptées pour répondre aux besoins spécifiques du diagnostic mammographique. Malgré ces obstacles, les avancées récentes montrent clairement que les techniques d'apprentissage profond, appliquées à des bases de données médicales à grande échelle, peuvent significativement améliorer la fiabilité des systèmes de diagnostic et la précision. À l'avenir, une plus grande standardisation des protocoles et l'élargissement des bases de données pourraient renforcer l'efficacité de ces méthodes et favoriser leur intégration plus généralisée dans le domaine clinique. Le Tableau II.6 offre un résumé des diverses recherches portant sur la classification des masses mammaires à travers l'utilisation de techniques fondées sur l'apprentissage profond.

5. Conclusion

L'avancement de l'apprentissage profond a considérablement bénéficié au développement des systèmes d'analyse d'images médicales. En particulier, pour les systèmes d'analyse assistée par ordinateur traitant le cancer du sein causé par des masses mammaires. Les techniques DL ont montré une performance remarquable dans la segmentation des muscles pectoraux, l'identification des masses dans les seins, et leur classification ultérieure. Leur popularité grandissante est due à leurs performances supérieures en comparaison avec les techniques conventionnelles. Cependant, pour augmenter davantage l'efficacité des systèmes de segmentation, des travaux supplémentaires s'imposent. En ce qui concerne l'identification des masses mammaires, l'utilisation de structures fondées sur des modèles traditionnels de reconnaissance d'objets a produit des résultats prometteurs. Néanmoins, plusieurs défis restent à relever. Les cadres de détection à une étape fournissent des résultats plus rapides mais souvent au détriment de la précision. En revanche, les cadres à deux étapes tendent à offrir une précision plus élevée mais nécessitent plus de ressources matérielles et de formation. Pour aborder ces défis, nous avons proposé un nouveau cadre de détection des masses mammaires qui intègre des techniques d'apprentissage profond axées sur la segmentation d'instance. Ce cadre atteint une haute efficacité et précision. De plus, il est suffisamment robuste pour gérer des images

mammographiques de densités variées, améliorant son applicabilité dans divers scénarios cliniques. De nombreuses recherches ont indiqué une grande précision dans la classification des masses mammaires en recourant à des méthodes DL. Toutefois, ces techniques sont souvent validées sur des bases de données de petite taille, comme mini-MIAS ou des collections de données privées, ce qui restreint leur capacité à se généraliser. Pour lutter contre cette limitation et faire avancer davantage le domaine, j'ai entrepris la construction d'un nouvel ensemble complet d'images mammographiques appelé LAMIS-DMDB. Cet ensemble de données à grande échelle fournira une gamme diversifiée d'images nécessaires au développement de systèmes DAO plus robustes et généralisables.

En tirant parti des modèles de DL pré-entraînés pour extraire des caractéristiques et en transférant et affinant les CNN de pointe sur LAMIS-DMDB, Nous avons pour objectif d'améliorer la robustesse et la généralisabilité du système. L'affinement des modèles de DL pour atteindre une performance optimale peut être chronophage et parfois infaisable en raison de facteurs tels que les paramètres d'hyper-paramètre et la taille limitée des données. Par conséquent, développer des classificateurs avec une performance supérieure à moindre coût est essentiel. Alors que les classificateurs traditionnels ont été largement explorés, les nouveaux classificateurs restent sous-utilisés. En réponse à cela, j'ai proposé d'introduire de nouveaux classificateurs pour la tâche de classification des masses mammaires. Ces nouveaux classificateurs ont contribué à une performance de classification supérieure, démontrant leur potentiel en tant qu'ajout précieux aux systèmes DAO existants. En conclusion, les techniques fondées sur l'apprentissage profond ont significativement progressé les systèmes d'analyse d'images médicales. En intégrant des nouveautés telles que les systèmes de détection en multi-étapes, les nouveaux classificateurs utilisant l'apprentissage par transfert, et le développement du LAMIS-DMDB, la performance et la robustesse de ces systèmes peuvent être davantage accrues. Ces avancées promettent une détection et une classification du cancer du sein plus précises et efficaces, améliorant finalement les résultats pour les patients et soutenant la prise de décision clinique.

CHAPITRE III :
Contribution au Détection du Cancer
du Sein et Classification



Chapitre III :

Contribution au Détection du Cancer du Sein et Classification

1. Introduction

Pour les tâches d'analyse d'images médicales, la localisation des lésions est un élément indispensable pour les tâches de segmentation et d'analyse subséquentes. Pour l'analyse automatisée du cancer du sein à partir d'images mammographiques, l'accent principal est mis sur la détection et la classification des lésions. Bien qu'il existe de nombreux symptômes, y compris la masse mammaire, la calcification, l'asymétrie et la distorsion architecturale, qui peuvent être associés au cancer du sein, la masse mammaire se révèle être le symptôme le plus fréquent et le plus manifeste[123]. Ainsi, des méthodes efficaces et performantes de détection des masses mammaires revêtent une grande importance pour la détection et la classification du cancer du sein[5, 47]. La détection des masses mammaires, en tant que petite branche de la détection d'objets, peut être mise en œuvre via les Framework de détection d'objet existants. Cependant, les principaux problèmes qui subsistent sont le coût élevé du matériel pour entraînement et le besoin de base de données à grande échelle. Dans ce contexte, nous avons proposé un système de détection et de classification des masses cancéreuses du sein basé sur l'apprentissage par transfert. Dans le système proposé, deux étapes principales sont identifiées : la détection et la segmentation, suivies de la classification. Dans un premier temps, un modèle d'apprentissage en profondeur est entraîné pour détecter et segmenter les masses mammaires à partir des mammographies. Ce modèle utilise le Transfer Learning pour tirer parti des modèles pré-entraînés afin d'assurer une détection et une segmentation précises. Une fois les masses détectées et segmentées, elles sont classées en deux catégories : malignes et bénignes. Le modèle de classification s'appuie également sur l'apprentissage par transfert, en tirant parti des caractéristiques extraites de vastes ensembles de données d'images pour améliorer la précision. Au cours de la phase d'entraînement, le modèle de détection et de segmentation est affiné sur un ensemble de données de mammographies annotées, tandis que le modèle de classification

est entraîné sur des données étiquetées, indiquant si les masses sont malignes ou bénignes. Au cours de la phase d'inférence, le modèle intégré de détection et de segmentation identifie d'abord puis segmente les masses mammaires potentielles. Ces masses segmentées sont ensuite classées par le modèle de classification en catégories malignes ou bénignes. Cette approche en deux étapes, combinant le Transfer Learning avec des modèles spécialisés pour chaque tâche, garantit une détection précise et une classification correcte des masses cancéreuses du sein, fournissant un outil fiable pour le diagnostic précoce et la planification du traitement. Le reste de ce chapitre examine en détail le processus de détection, de segmentation et de classification des masses mammaires, comme illustré dans la Figure III.1. Nous commençons par le prétraitement des données, où nous aborderons les techniques de normalisation et d'amélioration des données. Par la suite, nous nous penchons sur la méthode de détection et de segmentation automatiques des masses mammaires en utilisant MASK-RCNN, mettant en avant sa capacité avancée à localiser précisément les zones potentiellement malignes. La classification des masses mammaires est ensuite abordée à travers l'apprentissage par transfert, où différents modèles profonds sont évalués et comparés. Enfin, nous présentons les résultats expérimentaux obtenus, démontrant l'efficacité et la précision du système proposé pour la détection et la classification des masses mammaires, avec des implications significatives pour les applications cliniques futures.

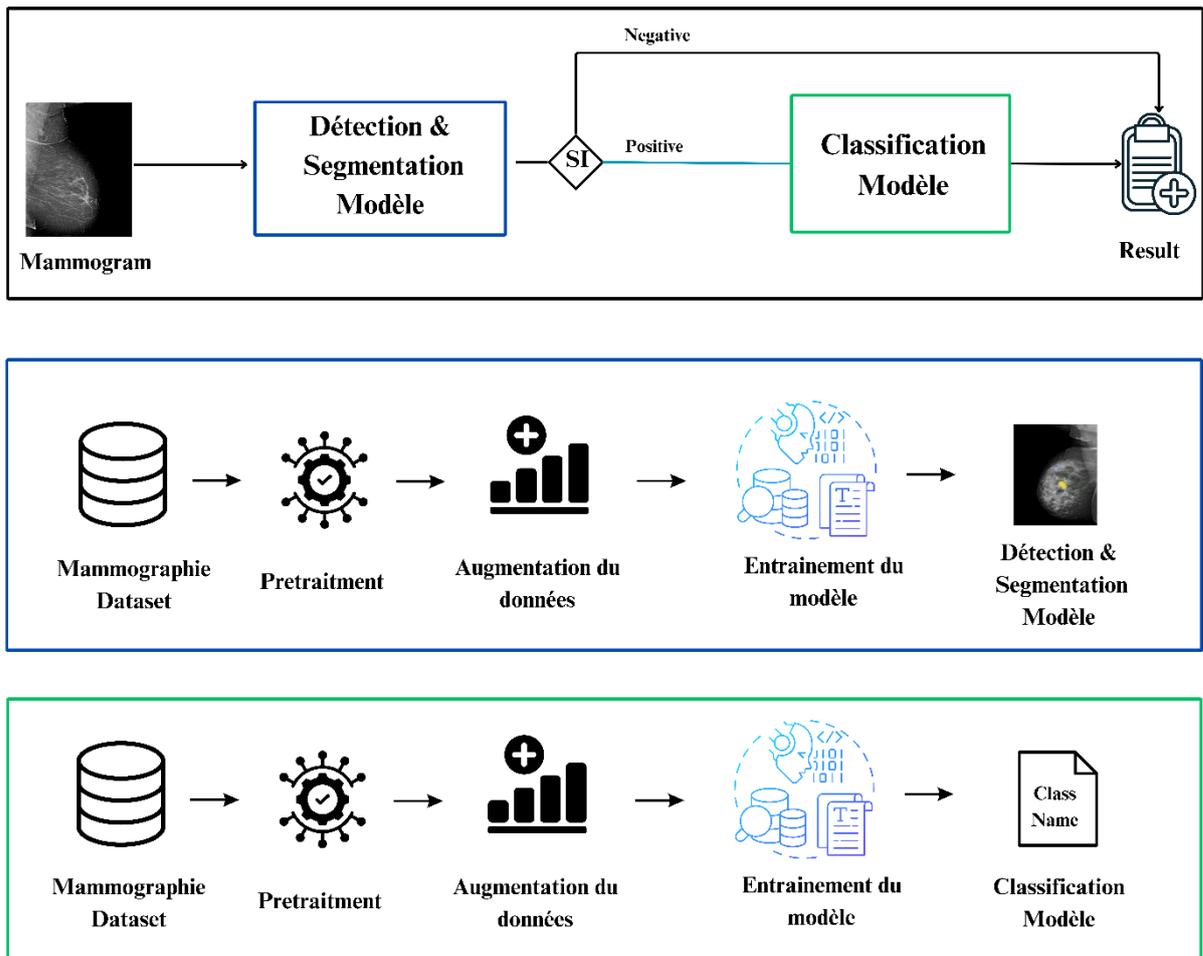


Figure III. 1:processus général Pour La détection et classification du masses mammaires

2. Détection et Segmentation Automatique du Mass mammaire

La détection et la segmentation précises des masses mammaires représentent des étapes essentielles pour le diagnostic précoce du cancer du sein. Les anomalies présentes dans une mammographie complète se trouvent souvent dans de petites zones qui ressemblent à du tissu mammaire normal, ce qui rend la tâche de détection particulièrement complexe. Pour relever ce défi, nous proposons un système intelligent en deux étapes, conçu pour détecter et identifier les masses dans les mammographies. La première étape de ce système est le prétraitement des données, qui consiste à préparer les images mammographiques pour les rendre exploitables lors des étapes suivantes. Cette phase de prétraitement comprend la conversion des images, la normalisation, l'amélioration de la qualité des images et l'augmentation des données afin de diversifier les échantillons d'entraînement. Une préparation adéquate est cruciale pour garantir la qualité et la fiabilité des analyses ultérieures. La deuxième étape concerne la détection et la segmentation des masses. Nous utilisons Mask RCNN[138], une architecture de réseau de neurones convolutifs avancée, pour identifier et segmenter les masses existantes, ou pour classer les cas comme normaux en l'absence de masses. Mask RCNN a été choisi pour sa capacité à fournir des segments d'objets précis et des délimitations précises des régions d'intérêt, dépassant les méthodes traditionnelles en matière de précision. Pour implémenter Mask RCNN, nous avons utilisé Detectron2, un Framework reconnu pour sa modularité et ses performances élevées dans les tâches de détection d'objets. Detectron2 facilite le développement, l'entraînement et l'évaluation de modèles complexes de détection[139]. Dans les sections suivantes nous détailleront ces étapes, les expérimentations menées, ainsi que les résultats recueillis et leur discussion.

2.1. Prétraitement des Données

L'étape de prétraitement des données est essentielle pour générer des ensembles de données mammographiques dans un format idéal pour la détection des masses. Les mammographies sont souvent stockées au format DICOM, qui présente des dimensions considérables dépassant celles généralement traitées par les algorithmes d'apprentissage profond. De plus, les annotations ne sont pas toujours enregistrées dans un format directement exploitable par ces algorithmes, nécessitant ainsi une conversion et une préparation supplémentaires.

Comme mentionné précédemment, les mammographies numérisées nécessitent davantage de processus de prétraitement par rapport aux FFDM. En effet, les FFDM, étant des images numériques directes, sont généralement de meilleure qualité et plus uniformes. Cependant, qu'il s'agisse de films numérisés ou de FFDM, un prétraitement rigoureux est indispensable pour obtenir des résultats précis. Les systèmes d'aide au diagnostic ont présenté de meilleures performances lorsqu'ils sont utilisés avec des FFDM, grâce à la qualité supérieure et à la moindre variabilité de ces images par rapport aux films numérisés.

Il est également à noter que des étiquettes peuvent parfois être visibles en haut de certaines mammographies, ajoutant des artefacts visuels. Même en l'absence de ces artefacts, le bruit peut persister dans les FFDM à cause de la poussière sur l'équipement de dépistage ou de mouvements involontaires. Pour cette raison, le prétraitement inclut plusieurs étapes critiques :

1. Conversion et Normalisation des Images : Toutes les images DICOM sont converties en format PNG afin de réduire l'espace de stockage nécessaire. Cette conversion s'accompagne d'une réduction de la résolution initiale de 14 ou 16 bits à une résolution de 8 bits, plus gérable pour les algorithmes d'apprentissage profond.

2. Annotation et Formatage des Données : Les annotations provenant des vérités terrain ou des fichiers XML fournis sont converties au format COCO. Cette standardisation permet une utilisation plus aisée et efficace des données dans les modèles d'apprentissage. Les figures 3 et 4 représente respectivement les annotations originales enregistre dans des fichiers indépendants pour chaque image et leur conversion au format COCO JSON. En convertissant les annotations au format COCO, nous simplifions l'intégration des données dans les Frameworks de détection d'objets modernes, ce qui facilite la manipulation et l'analyse des données annotées.

3. Augmentation des Données : Afin d'améliorer la robustesse et les performances des modèles, diverses transformations sont appliquées aux images. Cela inclut le retournement, la rotation, l'égalisation d'histogramme et le flou. Ces transformations augmentent la diversité des données d'entraînement, aidant ainsi les modèles à mieux généraliser sur des données inédites (Non vue). La figure 5 présente des exemples d'augmentation des images mammographiques, montrant comment ces transformations sont appliquées pour générer des variations des images originales, enrichissant ainsi la base de données.

En résumé, l'étape de prétraitement a pour objectif de garantir que les mammographies sont correctement formatées et annotées, prêtes à être utilisées lors des étapes suivantes de détection et de classification. Les transformations appliquées augmentent non seulement la taille des données d'entraînement, mais améliorent également la qualité des modèles en les rendant plus résilients face aux variations des données. La Figure III.2 illustre le processus complet de prétraitement des images mammographiques, y compris l'étape d'augmentation des données. Grâce à ces données prétraitées, nous sommes désormais en mesure d'appliquer des techniques avancées de détection et de segmentation pour identifier les masses mammaires. La section suivante présente la méthode Mask-RCNN, une approche de pointe permettant la détection et la segmentation automatiques des masses mammaires dans les images.

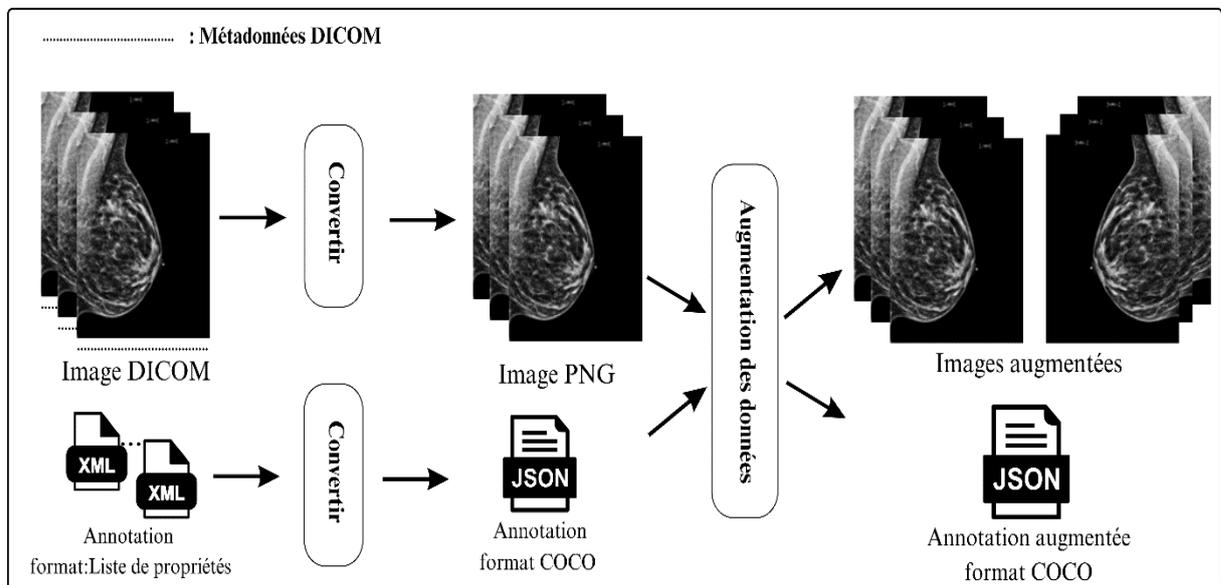
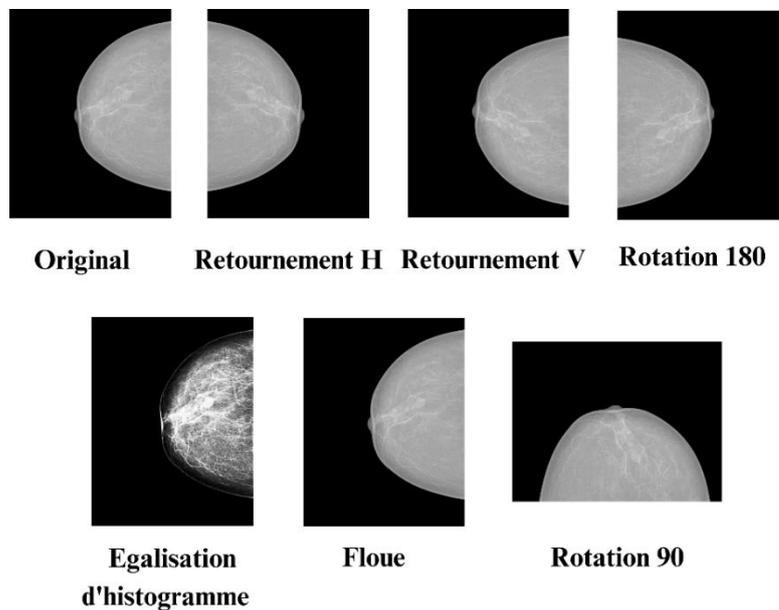


Figure III. 2: Le processus complet de prétraitement

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE plist PUBLIC "-//Apple//DTD PLIST 1.0//EN" "http://www.apple.com/DTDs/PropertyList-1.0.dtd">
<plist version="1.0">
<dict>
  <key>Images</key>
  <array>
    <dict>
      ....
      <key>NumberOfROIs</key>
      <integer>1</integer>
      <key>ROIs</key>
      <array>
        <dict>
          ...
          <key>Name</key>
          <string>Mass</string>
          <key>NumberOfPoints</key>
          <integer>62</integer>
          <key>Point_px</key>
          <array>
            <string>(1747.560059, 1367.180054)</string>
            <string>(1760.829956, 1357.520020)</string>
            ...
            <string>(1731.869995, 1381.660034)</string>
          </array>
          ....
        </dict>
      </array>
    </dict>
  </array>
</dict>
</plist>
```

Figure III. 3: Fichier d'annotation format liste de propriétés

```
object{2}
  filename:22580192.png
  regions[1]
    0{2}
      shape_attributes{3}
        name: polygon
        all_points_x[62]
          0:1747.560059
          1:1760.829956
          ...
          61:1731.869995
        all_points_y[62]
          0:1367.180054
          1:1357.52002
          ...
          61:1381.660034
      region_attributes{1}
        Class Name: MASS
```



Original Retournement H Retournement V Rotation 180

Egalisation d'histogramme Floue Rotation 90

Figure III. 4: Fichier d'annotation format COCO

Figure III. 5: Exemple des techniques d'augmentations applique sur la mammographie

2.2. Détection et Segmentation des Masses Mammaire avec MASK-RCNN

L'objectif principal du système proposé est de détecter précocement les symptômes des masses mammaires, une tâche souvent complexe pour les radiologues. Bien que de nombreux algorithmes de détection de masses pour les systèmes DAO aient été développés au fil du temps, les algorithmes de détection d'objets et de segmentation d'instances constituent des approches plus récentes et particulièrement efficaces pour la segmentation des masses. Dans le cadre de ce système, la technique Mask-RCNN est utilisée pour détecter et segmenter les masses mammaires présentes. La figure X présente le cœur de détection et segmentation proposé, basé sur la technique de segmentation d'instances utilisant Mask-RCNN. Cette méthode produit des masques de segmentation de haute qualité pour chaque objet qu'elle reconnaît avec précision dans une image. En comparaison avec Faster RCNN, Mask-RCNN apporte une amélioration significative en ajoutant une branche parallèle dédiée à la reconnaissance des boîtes de délimitation et une autre pour la prédiction des masques d'objets. Dans cette section, nous allons détailler le fonctionnement de Mask-RCNN, ses variantes et son architecture, et expliquer comment cette méthode est utilisée pour détecter et segmenter les masses mammaires.

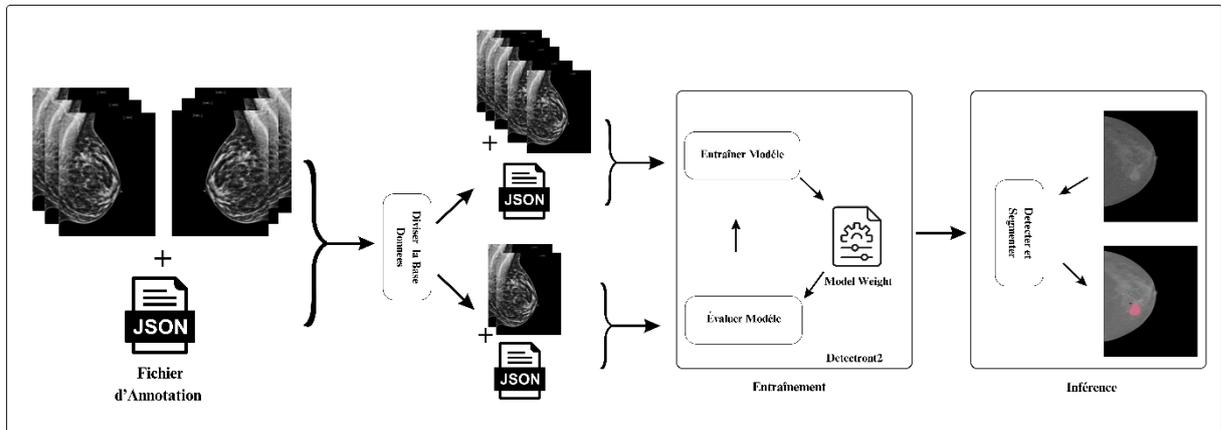


Figure III. 6: Le processus de détection et segmentation des masses mammaires avec Mask RCNN

2.2.1. Présentation du Mask RCNN

Mask-RCNN est une extension de Faster RCNN qui intègre une branche de segmentation de masques aux branches de classification et de localisation, et est largement reconnue comme une technique de pointe dans les tâches de segmentation d'instances. Cette technique est particulièrement puissante car elle permet non seulement de détecter les objets dans une image, mais aussi de générer un masque de segmentation précis pour chaque instance détectée. Mask-RCNN adopte un processus en deux étapes : tout d'abord, un réseau de propositions de régions génère des propositions de régions d'intérêt, puis ces régions sont affinées et segmentées par un réseau de détection et de segmentation [138, 140]. Les principaux avantages de Mask-RCNN incluent :

- **Segmentation Précise** : En plus des rectangles de délimitation, Mask-RCNN génère des masques de segmentation détaillés, ce qui améliore la précision de la détection des masses.
- **Architecture Modulaire** : La structure en deux étapes permet une flexibilité dans le choix des composants du réseau, facilitant les améliorations et les ajustements.

- **Haute Performance** : Grâce à l'intégration de la branche de segmentation, Mask-RCNN présente de meilleures performances en termes de précision par rapport aux méthodes antérieures telles que Faster RCNN.

La Figure III 7 illustre la structure du Mask-RCNN, montrant comment chaque composant contribue à la détection et à la segmentation des masses mammaires.

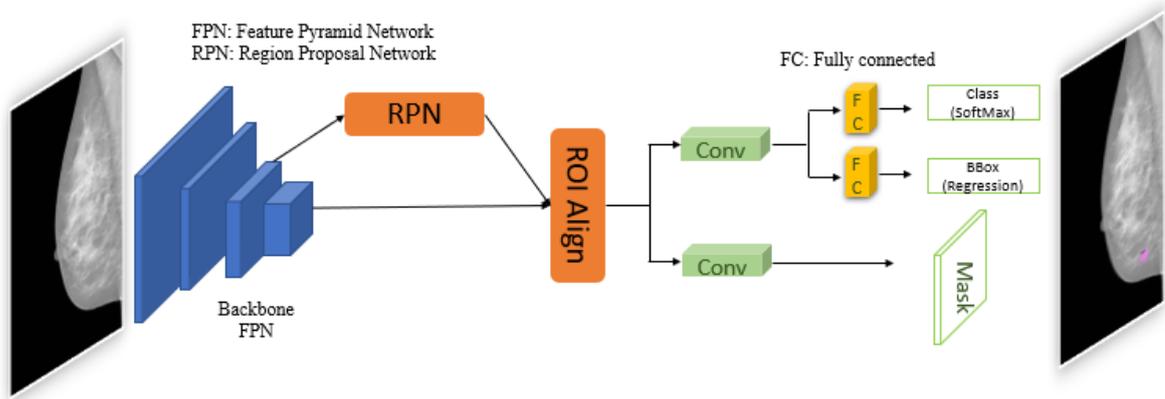


Figure III. 7: Architecture Générale du Mask-RCNN

2.2.2. Évolution des Techniques : De RCNN à Mask RCNN

Dans le domaine de l'analyse d'images contenant de multiples objets, les modèles de pointe actuels, tels que RCNN, Fast RCNN, Faster RCNN et Mask RCNN, ont démontré une efficacité remarquable pour l'identification et la localisation simultanées de plusieurs objets. Cette section examine les principes essentiels des principales techniques de détection et de segmentation d'objets, ainsi que leur évolution au fil du temps. Nous commencerons par RCNN, la première application des CNN à ce problème, puis nous examinerons ses successeurs, Fast RCNN et Faster RCNN, en mettant en lumière les améliorations apportées à chaque étape. Enfin, nous nous pencherons sur Mask RCNN, une méthode développée par Facebook Research Groupe, qui étend les techniques de détection d'objets pour offrir une segmentation précise au niveau des pixels. Comprendre pleinement Mask RCNN nécessite de revisiter d'abord les variantes de RCNN, en commençant par l'architecture originale de RCNN. Cette rétrospective permettra de saisir les avancées progressives et les améliorations apportées à chaque modèle, culminant avec la puissante méthode de segmentation d'instances qu'est Mask RCNN.

A. RCNN

RCNN constitue une approche majeure en détection d'objets, son objectif principal est de générer des boîtes englobantes annotées pour chaque objet détecté. Pour ce faire, RCNN utilise un processus appelé "Selective Search" qui propose des boîtes candidates en examinant l'image à différentes échelles et en regroupant les pixels adjacents selon leur texture, couleur et intensité. Ces régions proposées sont redimensionnées à une taille standard et traitées par une version modifiée d'AlexNet, un CNN qui a remporté la compétition ImageNet 2012. La couche finale du CNN est suivie d'une SVM qui classe chaque région en déterminant si elle contient un objet et, le cas échéant, quel est cet objet[141].

Pour améliorer la précision de la localisation, RCNN applique une régression linéaire simple pour ajuster les coordonnées des boîtes englobantes, assurant ainsi une meilleure adaptation autour des objets détectés. En résumé, RCNN inclut les étapes suivantes : la génération de propositions de régions, la classification de ces régions à l'aide d'un AlexNet pré-entraîné et d'un SVM, ainsi que l'affinage des boîtes englobantes par régression linéaire pour améliorer la précision de la détection[141].

B. Fast RCNN

Fast RCNN, développé par Ross Girshick en 2015, représente une amélioration significative de l'efficacité par rapport à la méthode précédente, RCNN. L'une des principales innovations de Fast RCNN est l'introduction du RoI Pooling, qui permet de partager les calculs du CNN sur toute l'image, réduisant ainsi le nombre de passes nécessaires. Plutôt que d'exécuter le CNN pour chaque proposition de région (environ 2000 par image dans RCNN), Fast RCNN exécute le CNN une seule fois par image et utilise le RoI Pooling pour extraire les caractéristiques de chaque région[142].

De plus, Fast RCNN a simplifié le processus d'entraînement en intégrant la formation du CNN, du classificateur et du régresseur de boîtes englobantes dans un seul modèle. Il emploie une couche entièrement connectée avec une fonction d'activation Softmax pour la classification, ainsi qu'une couche de régression linéaire pour estimer les coordonnées des boîtes englobantes. Ces innovations ont permis à Fast RCNN d'être non seulement plus rapide, mais aussi plus efficace que RCNN, tout en produisant des résultats de détection d'objets de haute qualité.

C. Faster RCNN

Faster RCNN, développé par une équipe de Microsoft Research en 2015, représente une avancée majeure dans les méthodes de détection d'objets. Il améliore l'efficacité de Fast RCNN en incorporant directement la génération de propositions de régions dans l'architecture du réseau convolutionnel, facilitée par un Réseau de Propositions de Régions (RPN). Le RPN est un réseau de neurones convolutifs totalement connecté qui analyse la carte des caractéristiques pour identifier des régions d'intérêt[143].

L'innovation principale de Faster RCNN réside dans sa capacité à réutiliser les caractéristiques de l'image extraites par le CNN pour générer des propositions de régions, éliminant ainsi le besoin d'un algorithme séparé. Le RPN utilise une approche de fenêtre glissante à travers la carte des caractéristiques du CNN pour générer plusieurs boîtes englobantes potentielles ainsi que leurs scores de probabilité. Cette méthode de fenêtre glissante permet de repérer les objets à différentes échelles et positions. Les entrées du modèle Faster RCNN consistent en les images elles-mêmes, tandis que les sorties comprennent à la fois les classifications des objets présents dans ces images et les coordonnées correspondantes des boîtes englobantes. Cette incorporation de la génération de propositions de régions améliore considérablement l'efficacité et la précision du modèle, facilitant une détection d'objets plus rapide et plus précise dans les images. En ce qui concerne le temps d'entraînement et le temps d'inférence, Faster RCNN est plus performant que Fast RCNN[144].

D. MASK RCNN

Mask RCNN, développé par Kaiming He et une équipe de chercheurs chez Facebook AI, représente une avancée significative dans le domaine de la segmentation d'images. Cette méthode, conçue comme une extension de Faster RCNN, vise à localiser précisément les pixels

de chaque objet dans une image, allant au-delà de la simple délimitation par des boîtes englobantes. [138]

L'idée sous-jacente à Mask RCNN est de combiner les performances de Faster RCNN en matière de détection d'objets avec la capacité de segmenter les objets au niveau des pixels. Pour ce faire, Mask RCNN ajoute une branche supplémentaire au réseau Faster RCNN, dédiée à la génération de masques binaires indiquant la présence d'objets à l'échelle pixelaire. Ces masques, produits par une architecture de réseau entièrement convolutionnel, identifient de manière précise les pixels appartenant à chaque objet dans l'image. Une adaptation importante apportée par les auteurs de Mask RCNN est l'introduction de RoIAlign, une méthode destinée à résoudre les problèmes de désalignement lors de la sélection des régions d'intérêt dans la carte des caractéristiques du CNN. En évitant les arrondis lors du processus de sélection des pixels, RoIAlign assure un alignement précis, crucial pour une segmentation d'image de haute qualité[145, 146].

En résumé, Mask RCNN se démarque par sa capacité à effectuer une segmentation d'image précise au niveau des pixels, alliant les atouts de la détection d'objets et ceux de la segmentation sémantique. Cette approche fournit des résultats de segmentation très précis et représente une avancée significative dans le domaine de la vision par ordinateur.

2.2.3. Le processus de Mask RCNN

Le processus de Mask R-CNN se décompose en plusieurs étapes essentielles, chacune jouant un rôle crucial dans la transformation d'une image brute en une représentation segmentée des objets qu'elle contient. Dans les sections suivantes, nous détaillerons chaque étape de ce processus, depuis l'extraction des caractéristiques initiales jusqu'à la génération des masques finaux, pour offrir une compréhension approfondie de cette technique puissante et polyvalente. La Figure III. 7 illustre la structure de Mask R-CNN, démontrant comment chaque étape contribue au processus global de Mask R-CNN[138, 146].

Étape 1 : Backbone

Le backbone représente la première étape de Mask R-CNN. Sa fonction est de convertir l'image brute en une représentation riche de ses caractéristiques visuelles en extrayant des éléments pertinents de l'image d'entrée. Il comprend généralement plusieurs couches de convolution, des opérations de pooling et d'autres fonctions non linéaires, ce qui permet de capturer des informations allant des niveaux bas aux niveaux élevés de l'image.

Étape 2 : Réseau de Propositions de Régions (RPN)

En s'appuyant sur les caractéristiques extraites par le réseau backbone, le RPN analyse l'image et suggère des régions d'objets possibles en utilisant des boîtes englobantes prédéfinies. Ces boîtes d'ancrage, qui varient en termes de rapports d'aspect et d'échelles, servent de contours potentiels autour des objets. Le RPN attribue un score à chaque proposition de région, indiquant sa similarité avec un objet réel. Un score élevé indique une forte probabilité de présence d'un objet d'intérêt dans la région suggérée, tandis qu'un score faible suggère que la région est probablement un arrière-plan ou ne contient pas d'objet pertinent.

Étape 3 : Réseau de Pyramide de Caractéristiques (FPN)

Mask R-CNN utilise un FPN pour aborder le défi de la représentation des caractéristiques à plusieurs échelles. Le FPN génère une pyramide de caractéristiques en fusionnant les données

issues de différentes couches d'un réseau de neurones convolutionnel. Cette structure pyramidale permet d'obtenir une représentation multi-échelle de l'image, avec des niveaux de caractéristiques à des résolutions spatiales variées.

Étape 4 : Alignement des Régions d'Intérêt (RoI Align)

Une fois la pyramide de caractéristiques établie par le FPN, les propositions de régions générées par le RPN sont exploitées pour extraire les caractéristiques des régions d'intérêt. À ce stade, le processus d'alignement des Régions d'Intérêt (RoI Align) entre en jeu. Plutôt que de recourir à l'opération classique de RoI Pooling, qui peut engendrer des problèmes d'alignement imprécis, Mask R-CNN utilise RoI Align. Cette méthode fait appel à l'interpolation bilinéaire pour échantillonner les caractéristiques à partir de la carte des caractéristiques initiale, assurant ainsi un alignement précis et une localisation exacte des contours des objets.

Étape 5 : Classification et Régression des Boîtes Englobantes

Après avoir généré et aligné les propositions de régions grâce à RoI Align, Mask R-CNN effectue ensuite la classification et la régression des boîtes englobantes. Les caractéristiques alignées sont envoyées à travers un réseau de neurones entièrement connecté, qui évalue les probabilités de classe pour chaque région proposée. Ce réseau modifie également les coordonnées des boîtes englobantes pour optimiser leurs positions et dimensions, garantissant ainsi une classification et une localisation précises des objets.

Étape 6 : Tête de Masque et Prédiction des Masques

La tête de masque du réseau a pour mission de produire des masques au niveau des pixels pour chaque objet identifié. Elle utilise les caractéristiques alignées par RoI en les faisant passer à travers plusieurs couches de convolution et d'opérations de suréchantillonnage, afin de générer les masques de segmentation finaux. Cette branche de prédiction des masques, qui inclut un classificateur binaire, détermine si chaque pixel est associé à l'objet (premier plan) ou au fond (arrière-plan). En conséquence, on obtient un masque de haute résolution pour chaque instance d'objet, permettant de définir avec précision ses contours. Ce processus complexe permet à Mask R-CNN d'assurer une détection et une segmentation efficaces des instances d'objets dans une image, en intégrant diverses techniques avancées de traitement d'images et d'apprentissage en profondeur.

3. Classification des Masses Mammaires

L'analyse des mammographies anormales conduit principalement à l'identification des boîtes englobantes des tumeurs, sans pour autant permettre de déterminer si celles-ci sont bénignes ou malignes. Par conséquent, Pour créer un modèle complet de détection et de classification, il est crucial d'évaluer les tumeurs identifiées afin de les classer comme bénignes ou malignes. Cette section explique le processus de classification des masses mammaires à l'aide de méthodes avancées d'apprentissage en profondeur et d'apprentissage par transfert. Grâce aux avancées en Deep Learning, nous disposons désormais de nombreuses méthodes pour résoudre des problèmes complexes dans divers domaines, y compris l'imagerie médicale. Cependant, amorcer le processus de classification à partir de zéro requiert une quantité

considérable de données étiquetées, souvent difficile à obtenir dans le domaine médical. L'apprentissage par transfert est une méthode de Deep Learning qui permet de contourner cette limitation. Cette technique consiste à réutiliser un modèle préalablement entraîné sur une tâche similaire et à l'adapter pour résoudre un nouveau problème[47, 59].

Le processus de classification des masses mammaires, illustré à la Figure III. 8, suit cette approche. Suite à la détection préliminaire des masses tumorales, la responsabilité de la classification est attribuée à des réseaux de neurones convolutionnels profonds. Ces réseaux, grâce à leur capacité à apprendre des représentations hiérarchiques des données, sont particulièrement bien adaptés pour distinguer les tumeurs bénignes des tumeurs malignes. À cette fin, plusieurs modèles pré-entraînés sont employés de manière individuelle. Étant formés sur des ensembles de données vastes et variés, ces modèles présentent une robustesse et une meilleure capacité de généralisation. Leur réentraînement sur des données spécifiques aux tumeurs mammaires permet de raffiner leur précision et d'améliorer leurs performances diagnostiques.

En conclusion, la combinaison des techniques de Deep Learning et de Transfer Learning aide à relever les défis associés à la classification des tumeurs mammaires. Ce processus, en optimisant l'utilisation des données disponibles et en tirant parti des modèles préexistants, propose une méthode avancée et précise pour le dépistage et le diagnostic du cancer du sein. Cette approche joue un rôle essentiel dans l'optimisation des techniques de détection précoce et de traitement personnalisé, ce qui accroît les chances de survie et améliore la qualité de vie des patientes.

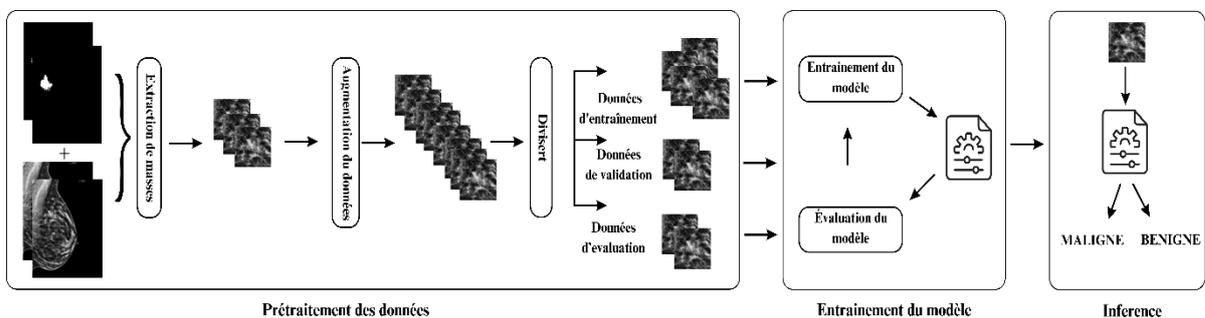


Figure III. 8: Processus e classification des masses mammaires

3.1.Prétraitement des Bases de Données

Dans le cadre de cette recherche, il n'y a pas de base de données publique contenant des patches, c'est-à-dire des sections recadrées d'images de mammographies numériques présentant des masses, qui sont essentielles pour le développement et l'entraînement de modèles de détection et de classification des masses mammaires. Pour remédier à cette lacune, nous avons constitué une base de données de masses en utilisant la base de données de mammographies INbreast. La création de cette base de données a impliqué le découpage des masses à partir des images complètes de mammographies, en se basant sur les vérités terrain et les annotations fournies par des radiologues experts. Plus précisément, nous avons employé des algorithmes de détection pour localiser les boîtes englobantes des masses, puis extrait les régions correspondantes des mammographies. La figure III. 9 présente un exemple des masses extraites.

En raison du nombre insuffisant de cas dans la base de données, l'augmentation de données est nécessaire pour générer de nouvelles données d'entraînement à partir des données existantes. Nous avons appliqué des transformations telles que le retournement (horizontal et vertical) et la rotation dans une plage d'angles spécifiée (par exemple, de 90° à 180°) afin de simuler des variations courantes dans la présentation clinique des masses. Ces transformations permettent d'enrichir la base de données en introduisant des variations réalistes et pertinentes, ce qui améliore la performance du modèle à généraliser et à reconnaître les masses sous différentes perspectives et configurations. Les détails peuvent être vus dans *ALGORITHME 1*. Une fois la base de données préparée et enrichie grâce à ces étapes de prétraitement, nous entamons la phase de classification des masses, durant laquelle nous appliquerons des CNN pour différencier les masses bénignes des masses malignes.

ALGORITHME 1 : Extraction et Augmentation Patches Masses

ENTRÉE :

image_mammographie: Image de mammographie

annotations_masses: Annotations des masses

augmentation : Booléen indiquant si l'augmentation des données doit être appliquée

SORTIE :

patches_masses: Patches correspondant aux masses extraites et éventuellement augmentées de l'image.

DÉBUT

patches_masses <- []

POUR CHAQUE *annotation_masses* ***DANS*** *annotations_masses* ***FAIRE***

boite_englobante <- Calculer_boite_englobante(*annotation_masses*)

patch_masse <- Extraire_patch(*image_mammographie*, *boite_englobante*)

SI *augmentation* ***EST VRAI ALORS***

patches_augmentes <- Appliquer_Augmentation(*patch_masse*)

AJOUTER *patches_augmentes* ***À*** *patches_masses*

SINON

AJOUTER *patch_masse* ***À*** *patches_masses*

FINSI

FINPOUR

RETOURNER *patches_masses*

FIN

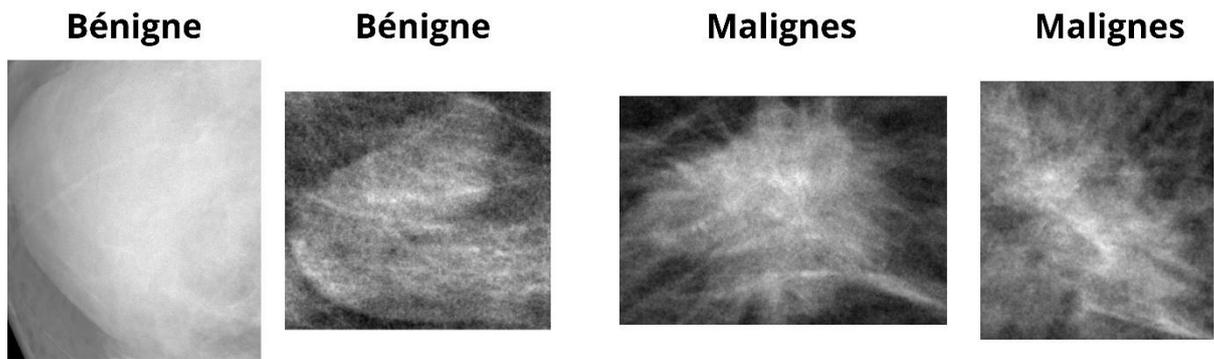


Figure III. 9: Exemple des masses extraits

3.2. Classification des Masses Avec l'Apprentissage par Transfert

Après le prétraitement et l'augmentation des données, notre prochaine étape cruciale est la classification des masses détectées. L'objectif est de déterminer si les masses identifiées sur les mammographies sont bénignes ou malignes, une tâche essentielle pour orienter le diagnostic et le traitement des patients. Pour atteindre cet objectif, nous avons recours aux CNN pré-entraînés, en appliquant une technique d'apprentissage par transfert. L'apprentissage par transfert consiste à prendre un modèle qui a déjà été formé sur une grande base de données pour une tâche spécifique et à l'adapter à une nouvelle tâche, en l'occurrence, la classification des masses mammaires. Cette technique est particulièrement avantageuse dans notre contexte où les données annotées sont souvent limitées et coûteuses à obtenir.

Nous avons expérimenté avec plusieurs architectures de CNN pré-entraînés, telles que ResNet34, ResNet101, AlexNet, VGG16, VGG19 et DenseNet121. Ces modèles ont été préalablement entraînés sur de grandes bases de données d'images, telles qu'ImageNet, ce qui leur confère une capacité d'extraction de caractéristiques visuelles très efficace. Le réentraînement des modèles s'effectue en plusieurs étapes. Tout d'abord, nous ajustons les couches finales des modèles pré-entraînés pour qu'elles soient adaptées à notre tâche spécifique. Nous procédons ensuite à un entraînement supplémentaire sur notre base de données de mammographies augmentées, en appliquant des techniques d'apprentissage par transfert pour ajuster les paramètres du modèle et renforcer sa capacité à différencier les masses bénignes des masses malignes. L'apprentissage par transfert nous permet de tirer parti de la robustesse et de la précision des modèles de CNN pré-entraînés tout en les adaptant aux caractéristiques spécifiques de notre jeu de données médical. Cette méthode nous procure une performance supérieure par rapport à l'entraînement de nouveaux modèles depuis le début, tout en nécessitant moins de ressources computationnelles et de données annotées.

La classification des masses mammaires via l'apprentissage par transfert de modèles de CNN pré-entraînés constitue une méthode efficace et performante pour différencier les masses bénignes des masses malignes, contribuant ainsi à une meilleure prise en charge des patientes.

4. Expérimente et Résultats

Dans la section précédente, nous avons exposé en détail la méthodologie employée pour détecter, segmenter et classifier les masses mammaires. La présente section est dédiée à la description des expériences réalisées et à l'analyse des résultats obtenus afin d'évaluer l'efficacité de notre système. Nous débutons par une présentation exhaustive du jeu de données utilisé pour nos expérimentations, en mettant en lumière ses principales caractéristiques et le processus de préparation. Par la suite, nous fournissons des informations détaillées sur la plateforme et les outils employés pour l'exécution des expériences. Nous présentons ensuite les diverses métriques employées pour évaluer l'efficacité de notre système dans la détection et la classification des masses mammaires. Parmi ces métriques figurent des indicateurs tels que la précision, l'accuracy et le F1-score, qui sont cruciaux pour une évaluation exhaustive et rigoureuse. Enfin, la sous-section suivante est dédiée à la présentation et à l'analyse des résultats obtenus. Nous évaluons les performances de notre système en les confrontant aux méthodes de pointe existantes, tout en mettant en avant les atouts et les limites de notre approche. Les résultats démontrent l'efficacité et la robustesse de notre système dans diverses conditions expérimentales, ouvrant ainsi des perspectives prometteuses pour son application clinique.

4.1. Base de données utilisée

Pour nos expériences, nous avons choisi la base de données INbreast, qui est largement reconnue comme l'une des rares références contenant des mammographies FFDM accompagnées d'annotations très précises des lésions pour chaque cas. Contrairement à d'autres bases de données telles que MIAS et DDSM, qui contiennent des mammographies numérisées avec des annotations de moindre précision, INbreast se distingue par la confirmation et la certification de ses données par deux experts. Comme mentionné au chapitre I, INbreast est considérée comme une ressource de haute qualité. Il convient de noter qu'au moment de notre utilisation, l'accès à INbreast nécessitait une demande formelle. Récemment, cette base de données est désormais accessible publiquement. La Figure 10 offre des informations complémentaires sur cette base de données, tandis que la Figure 11 montre un exemple extrait de la base de données INbreast.

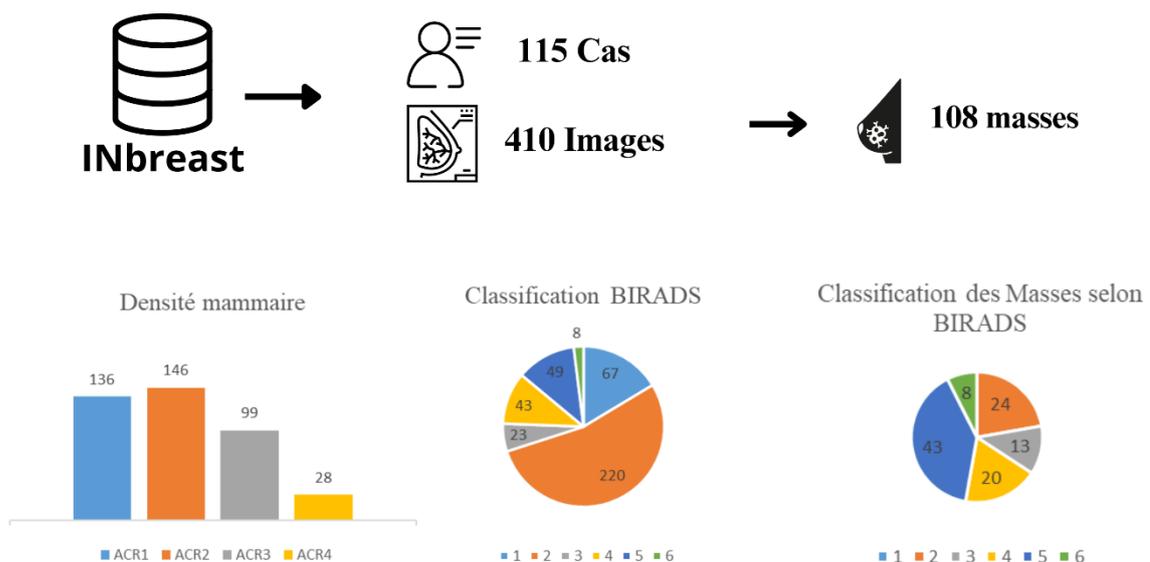


Figure III. 10: Détails de la base de données INbreast

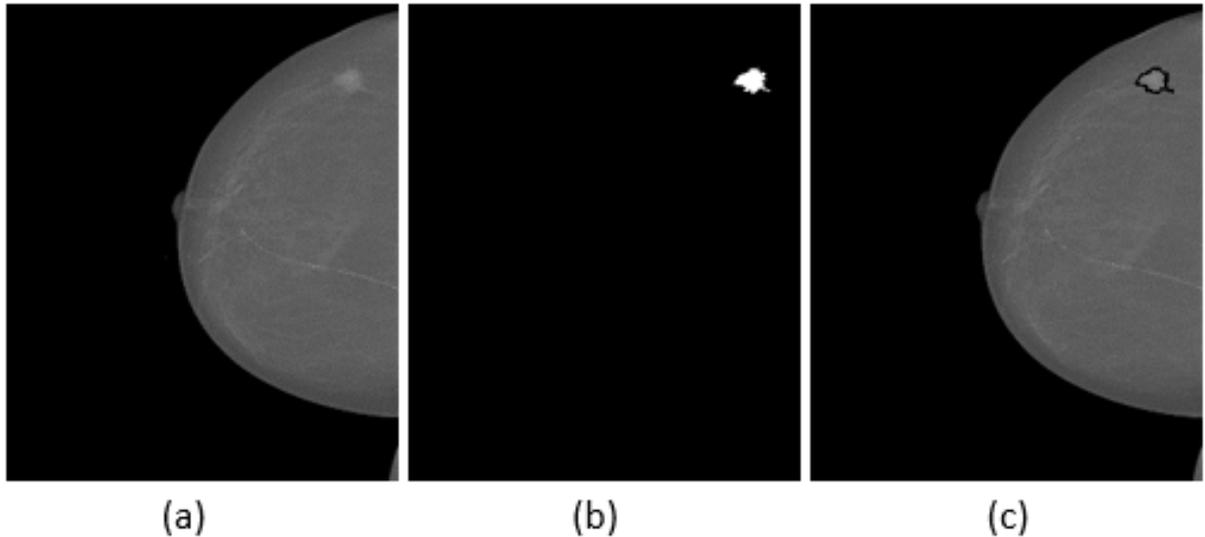


Figure III. 11: Échantillon de la base de données INbreast ; ID=20587612_f4b2d377f43ba0bd_MG_R_CC_ANON ;a) : Image de mammographie ;(b) : Vérité terrain (masque) ;(c) : Mammographie avec vérité terrain

4.2.Évaluation et Performances

Afin d'évaluer la performance de notre système proposé, nous nous appuyons sur plusieurs métriques d'évaluation utilisées pour évaluer la précision de la détection des masses et d'autres pour mesurer la performance de la classification des masses. L'efficacité du modèle dans la détection des cancers sur les mammographies a été analysée en utilisant la métrique Intersection Over Union (IOU).

$$IOU[U, V] = \frac{U \cap V}{U \cup V} \quad (1)$$

Nous considérons qu'une masse est correctement détectée si l'IOU est supérieur ou égal à 0,5 ; sinon, la détection est ignorée. La matrice de confusion est l'une des mesures importantes utilisées pour évaluer les métriques de classification. À cette fin, après avoir classifié la masse en utilisant un classificateur spécifique, nous déterminons son type et le comparons avec son type réel pour établir une matrice de confusion. Celle-ci se compose principalement de Vrai Négatif (VN) (VN : masse bénigne classifiée comme bénigne), Vrai Positif (VP) (VP : masse maligne classifiée comme maligne), Faux Positif (FP) (FP : masse bénigne classifiée comme maligne), et Faux Négatif (FN) (FN : masse maligne classifiée comme bénigne). Ces mesures nous permettent de calculer l'Accuracy, le Rappel et la Précision. Les formules pour les différentes métriques sont présentées ci-dessous:

$$Precision[P] = \frac{VP}{VP+FP} \quad (2)$$

$$Recall[R] = \frac{TP}{TP+FN} \quad (3)$$

$$Accuracy = \frac{VP+VN}{VP+VN+FP+FN} \quad (4)$$

$$F1_{Score} = 2 * \frac{P*R}{P+R} \quad (5)$$

La Précision Moyenne (Average Precision: AP) est une métrique couramment utilisée pour évaluer la précision des algorithmes de détection d'objets tels que DeepLap Faster R-CNN, SSD, etc. La Précision Moyenne détermine la valeur moyenne de la précision pour des niveaux de rappel variant de 0 à 1. La définition générale de l'AP consiste à trouver l'aire sous la courbe de précision-rappel.

$$AP = \int_0^1 p(r)dr \quad (6)$$

4.3. Détection et Segmentation

Dans le cadre de notre expérience visant à segmenter et détecter le cancer du sein, Des images ont été choisies dans la base de données INbreast pour constituer les ensembles d'entraînement et de validation. Les images ne présentant pas de masse et sans annotation de vérité terrain ont été exclues. Cela a résulté en 86 images pour l'entraînement et 11 pour la validation, et nous avons utilisé 11 images dans l'ensemble de test. Les annotations ont été stockées dans des fichiers JSON au format COCO, avec un fichier JSON pour l'entraînement et un autre pour la validation, qui seront utilisés par la plateforme Detectron2. De plus, diverses stratégies de data augmentation ont été appliquées dans cette expérience.

La première stratégie (S1) inclut des techniques d'augmentation qui ne modifient pas la valeur d'intensité des pixels, telles que la rotation et le retournement. La deuxième stratégie (S2) comprend des techniques d'augmentation comme le floutage et l'égalisation d'histogramme qui étendent les valeurs d'intensité des pixels les plus fréquentes ou étirent la plage d'intensité de l'image. Dans la dernière stratégie (S3), nous combinons toutes les techniques précédentes, comme indiqué dans le Tableau 1.

Tableau III. 1 : Techniques d'Augmentation de Données Appliquées

Technique	S1	S2	S3
Rotation [90,180]	X	-	X
Retournement	X	-	X
Floutage	-	X	X
Floutage moyen	-	X	X
Floutage médian	-	X	X
Floutage gaussien	-	X	X
Égalisation d'histogramme	-	X	X

L'entraînement du modèle Mask R-CNN dans Detectron2 nécessite certains hyperparamètres essentiels tels que le nom du Backbone. Dans notre cas, nous avons choisi deux backbones pour notre expérience : Mask R-CNN R 50 FPN 3x et Mask R-CNN R 101 FPN 3x. Les deux modèles ont été entraînés sur la base de données COCO et sont existé dans le modèle zoo de FAIR. Les autres hyperparamètres utilisés sont : Nombre de classes = 1 (mass), Nombre d'époques = 600, Taux d'apprentissage (Learning Rate) = 0.0025. Pour le reste des

hyperparamètres, Nous avons utilisé les paramètres par défaut qui sont fournis dans le fichier de configuration de Mask R-CNN.

Les performances de détection et de segmentation des masses mammaires obtenues par le fine-tuning de Mask R-CNN pour les deux backbones avec l'ensemble de test sont présentées dans le Tableau III.2. D'après les résultats obtenus après l'évaluation sur les données de test, les modèles entraînés avec S2, qui ont bénéficié d'une augmentation des données par des techniques telles que le floutage et l'égalisation d'histogramme, ont montré des performances inférieures par rapport aux autres modèles. Le modèle Mask R-CNN R 50 FPN 3x a mieux performé dans la détection des boîtes englobantes, atteignant une précision moyenne de 93,41%. En revanche, le modèle Mask R-CNN R 101 FPN 3x a obtenu de meilleurs résultats dans la génération des masques, avec une précision moyenne de 96,12%. Les résultats complets sont fournis dans le Tableau III.2. La Figure III.9 illustre des exemples des résultats qualitatifs concernant l'identification des lésions mammaires réalisée à l'aide du processus MASK-RCNN. Pour identifier les ROIs des lésions mammaires possibles, avec un ratio de chevauchement IoU élevé et un score de confiance de prédiction élevé. Grâce à MASK-RCNN, il est possible d'identifier précisément les boîtes englobantes entourant les lésions mammaires, de les aligner et de créer un masque avec une segmentation précise. La Figure 9 illustre les résultats de ce processus.

Tableau III. 2: Performance de Détection des masses et Segmentation

Backbone	S	AP		AP75		AP50	
		Bbox	Segm	Bbox	Segm	Bbox	Segm
Mask_rcnn_R_50_FPN_3x	S1	49.31	59.31	36.36	73.21	93.41	93.41
	S2	44.29	54.84	33.83	63.24	85.96	89.09
	S3	49.46	59.63	41.15	76.34	91.67	94.59
Mask_rcnn_R_101_FPN_3x	S1	45.16	57.76	41.15	70.53	90.84	93.99
	S2	43.93	55.50	36.86	65.03	89.13	92.05
	S3	44.93	57.04	42.61	65.34	92.23	96.12

En outre, le Tableau 5 compare les résultats de détection de Mask-RCNN avec ceux d'autres algorithmes actuels. Mask-RCNN a atteint une excellente précision de détection tout en ayant un temps de prédiction plus rapide. Mask-RCNN est également capable de détecter les masses, même dans les situations les plus complexes, telles que lorsque les lésions mammaires se trouvent dans des tissus mammaires denses, comme le montre la Figure III. 9. En comparaison avec les modèles de Deep Learning contemporains, comme le montre le Tableau III.5, le système proposé repose fortement sur le détecteur Mask-RCNN pour offrir la capacité nécessaire de détection des lésions mammaires.

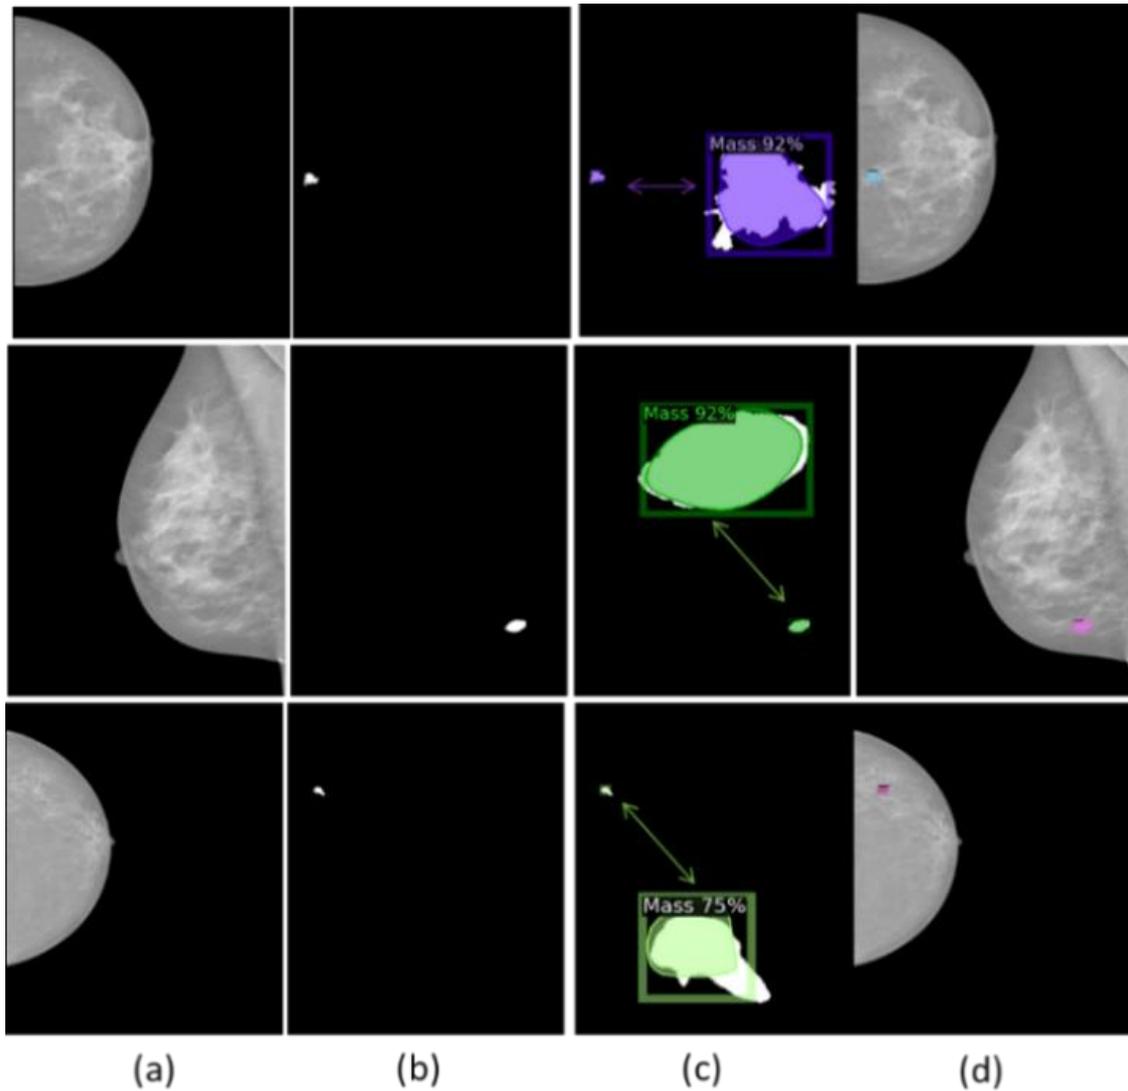


Figure III. 12 : Résultat de Détection et de Segmentation – (a) : Mammographie Originale ; (b) : Vérité de Terrain (Masque) ; (c) : Vérité Terrain avec Prédiction ; (d) : Résultats

4.4. Classification de masses

Après avoir élaboré l'ensemble de données de masses à partir de la base de données INbreast, nous avons appliqué des techniques de transformation telles que la rotation et le retournement afin d'équilibrer et d'enrichir cet ensemble de données. L'équilibrage des données a été réalisé en appliquant la transformation Flip Up, suivie des rotations de 90, 180, et 270 degrés, ainsi que les retournements à droite, à gauche et vers le bas afin d'augmenter les données.

Pour les modèles entraînés suivants : VGG16, VGG19, ResNet-34, ResNet-101, AlexNet et DenseNet121, chaque masse mammaire identifiée et segmentée a été normalisée et redimensionnée à une taille fixe de 224×224 pixels. La phase de classification utilise toutes ces images de masses mammaires comme entrée, produisant une prédiction finale pour déterminer si les cas sont malins ou bénins. En réalité, les modèles plus profonds tels que VGG16, VGG19, ResNet-34, ResNet-101, AlexNet et DenseNet121 sont comparés pour voir lequel est le plus performant en reconnaissance. Cette comparaison est réalisée dans des conditions d'entraînement et de test uniformes pour tous les modèles de Deep Learning.

Les couches sont spécifiquement entraînées et ajustées à l'aide de l'optimiseur Adam. Pour obtenir la meilleure précision dans la classification des masses, plusieurs ajustements des hyperparamètres sont réalisés durant l'entraînement du modèle. Les modules FastAI incluent ces hyperparamètres. Pour cette tâche, les hyperparamètres utilisés sont présentés dans le Tableau 3.

Tableau III. 3 : hyperparamètres utilisés

Hyperparamètres	Valeur
Taille de l'image	224
Optimiseur	Adam
Taux d'apprentissage (LR)	0.001
Nombre d'époques	60
Taille du lot (BS)	30

Avec les architectures de backbone et l'ajustement des hyperparamètres sur la bibliothèque Fastai PyTorch, Les modèles finaux ont obtenu des niveaux de précision de classification variés sur l'ensemble de données de validation. Le Tableau III. 4 présente quelques métriques de performance ainsi que leurs résultats sur l'ensemble de test. Il est clair que l'ajustement fin du modèle DenseNet121 a abouti à des performances de classification supérieures, avec une précision de 99 %, un F1-score de 99 % et une précision globale de 99,44 %. En revanche, le modèle VGG16 raffiné a obtenu les notes de performance les plus basses en classification par rapport aux autres modèles pour toutes les métriques d'évaluation, malgré les bons résultats qu'il a obtenus. Nous notons également que les modèles ResNet101 et AlexNet ont fourni les mêmes résultats et la même capacité à classifier les masses.

Tableau III. 4: Performance de classification des masses mammaire

Classifieur	VN	VP	FP	FN	Précision	Recall	F1_Score	Accuracy
VGG16	89	81	9	1	0.90	0.99	0.94	94.44
VGG19	90	84	6	0	0.93	1.00	0.97	96.67
ResNet50	89	84	6	1	0.93	0.99	0.96	96.11
ResNet101	89	86	4	1	0.96	0.99	0.97	97.22
AlexNet	89	86	4	1	0.96	0.99	0.97	97.22
DenseNet121	90	89	1	0	0.99	1.00	0.99	99.44

De plus, le modèle final ne souffre pas de surapprentissage puisque les pertes initiales d'entraînement et de validation commencent à des niveaux élevés et diminuent progressivement jusqu'à des valeurs presque indiscernables au cours des époques. La Figure III. 13 illustre graphiquement l'évolution des pertes durant les phases d'entraînement et de validation. La performance prometteuse de classification de notre système entièrement intégré est atteinte pour diverses raisons. Tout d'abord, les ROIs des masses mammaires potentielles sont efficacement identifiés à l'aide du modèle de prédiction Mask RCNN. Par la suite, les cartes de

caractéristiques de haut niveau produites par des modèles de Deep Learning avancés contribuent à une amélioration notable de la performance diagnostique globale du système.

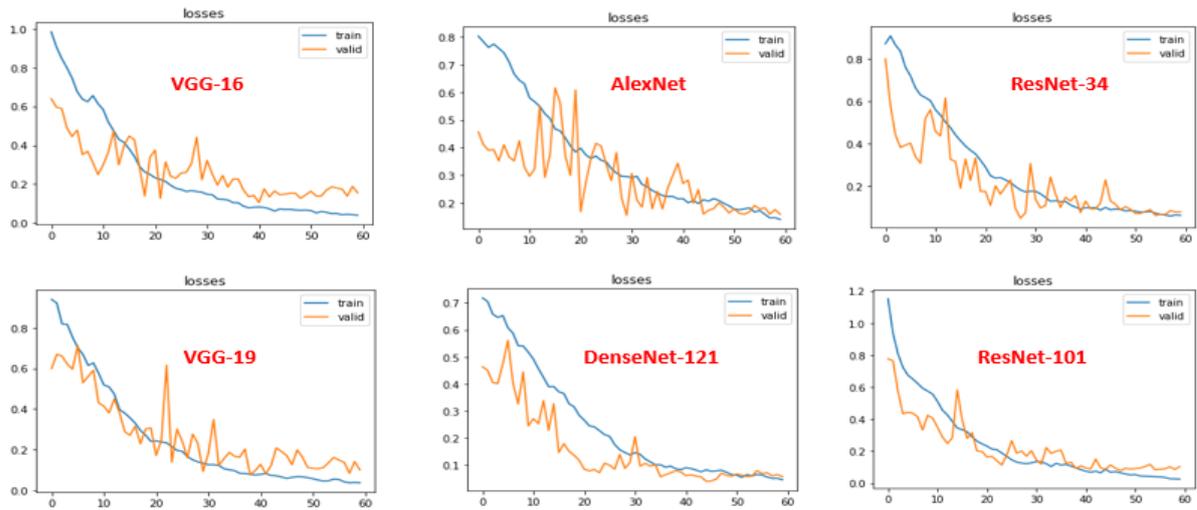


Figure III. 13: Courbes de pertes d'entraînement et de test

4.5. Discussion

Le tableau suivant présente une comparaison de diverses méthodes de détection, segmentation et classification des masses mammaires sur plusieurs ensembles de données. Notre approche, basée sur Mask RCNN pour la détection et segmentation des masses, obtient un Average Precision (AP) de 96,12 % et une précision de détection (Acc) de 98,23 %. Ces résultats sont comparables, voire supérieurs, à ceux des autres méthodes comme YOLO-V1 & FrCN (AP=97.27) et YOLO-V4 (AP=97.86). L'utilisation de Mask RCNN s'est avérée particulièrement efficace pour localiser les masses avec une haute précision, grâce à sa capacité à générer des masques de segmentation précis. Pour la classification, nous avons opté pour DenseNet121, qui s'est révélé plus performant que les autres approches, atteignant une précision de 99,44 %. En comparaison, les méthodes utilisant Inception-ResNet V2 et Inception V3 ont respectivement atteint 97.50% et 91%. Notre modèle DenseNet121 offre une meilleure performance en termes de précision, démontrant sa capacité à classifier correctement les masses mammaires, même dans des cas complexes. De plus, notre système a été entraîné et évalué sur Google Colab, démontrant ainsi une flexibilité et une accessibilité accrues par rapport aux autres méthodes utilisant des GPU haut de gamme comme Nvidia GTX 1080 et RTX 2080. Cela indique que notre approche est non seulement performante, mais aussi plus accessible pour les chercheurs avec des ressources informatiques limitées. Notre approche se démarque par sa capacité à fournir des résultats hautement précis dans la détection, la segmentation, et la classification des masses mammaires. Grâce à l'utilisation de Mask RCNN, nous garantissons une localisation précise des masses. DenseNet121, en tant que modèle de classification, prouve sa supériorité avec une précision de 99.44%, surpassant les modèles comparés. De plus, l'utilisation de Google Colab pour l'entraînement et l'évaluation de notre modèle démontre que des résultats exceptionnels peuvent être obtenus sans nécessiter des infrastructures coûteuses. Cette approche accessible et performante rend notre méthode particulièrement attractive pour une adoption plus large dans des environnements de recherche et cliniques. En somme, notre système intégré propose une solution fiable et précise pour la détection, la segmentation, et la classification des masses mammaires, démontrant ainsi son potentiel pour des utilisations pratiques et cliniques.

Tableau III. 5 : Comparaison des Méthodes de Détection, Segmentation et Classification

Paper	Detection and segmentation method	Classification method	Dataset	IOU	AP /detection ACC	Classification Accuracy	GPU
[147]	YOLO-V1&FrCN	CNN	INbreast	0.5	Acc=97.27	98.96%	Nvidia GTX 1080
[48]	YOLO-V2	Inception-ResNet V2	INbreast & DDSM	0.5	Acc=97.27 Acc=99.17	95.32% 97.50%	Nvidia GTX 1080
[54]	YOLO -V4	Inception V3	INbreast	0.5	AP=97.86	91%	Nvidia RTX 2080
Ours	Mask RCNN	DensetNet121	INbreast	0.5	Acc=98.23 AP=96.12	99.44%	Google Collab

5. Conclusion

Dans ce chapitre, nous avons présenté un système intelligent d'assistance au diagnostic du cancer du sein reposant sur des techniques d'apprentissage profond, capable de localiser de manière fiable toute zone suspecte de cancer dans le sein et de déterminer si elle est bénigne ou maligne si elle est présente. Dans un premier temps, le modèle Mask R-CNN, employé pour la détection et la segmentation, a été formé à l'aide d'un ensemble de données de mammographies provenant de la base INbreast. Il a été démontré que le modèle Mask R-CNN, initialement formé sur un ensemble de données d'images naturelles complètement différent (la base de données COCO), pouvait être modifié pour détecter efficacement les masses dans les mammographies complètes. De plus, le modèle Mask R-CNN excelle particulièrement dans la localisation des petites tumeurs. Après la détection des régions cancéreuses, Divers classificateurs ont été ajustés sur l'ensemble de données des masses mammaires, issues de la base INbreast, utilisée dans les études sur le diagnostic du cancer du sein. Sur la base des résultats obtenus, DenseNet-121 a été retenu comme le modèle le plus performant, surpassant les cinq autres modèles testés pour la classification des masses détectées. En mettant en parallèle le système proposé pour la détection, la segmentation et la classification des masses avec d'autres études disponibles dans la littérature, il a été constaté qu'il offrait de meilleures performances en termes de précision et d'exactitude. Un avantage notable du système suggéré est qu'il peut être utilisé dans un cadre clinique, car il utilise l'intégralité de la mammographie comme entrée et produit toute masse suspecte détectée en sortie. En résumé, notre système intégré fournit une solution fiable et précise pour la détection, la segmentation et la classification des masses mammaires, prouvant ainsi son utilité pour des applications cliniques et réelles.

CHAPITRE IV : LAMIS-DMDB
La Base de Données Algérienne de
Mammographie



Chapitre IV :

LAMIS-DMDB La Base de Données Algérienne de Mammographie

1. Introduction

Les bases de données de mammographie numérique jouent un rôle crucial dans le dépistage, le diagnostic et le traitement du cancer du sein. Les avancées technologiques en imagerie numérique permettent désormais de capturer des images mammographiques de haute qualité, ce qui favorise une détection plus précoce et précise des anomalies mammaires. Des bases de données existantes, telles qu'INbreast, MIAS et DDSM, ont offert des ressources précieuses pour la recherche et le développement d'algorithmes de détection et de classification des masses mammaires. Cependant, elles présentent certaines limites, notamment en ce qui concerne la précision des annotations et la diversité des cas[35].

Dans ce cadre, nous avons initié la création d'une nouvelle base de données de mammographie numérique, conçue pour surmonter ces limitations. Notre objectif est de fournir des images mammographiques de haute résolution, accompagnées d'annotations précises et fiables, validées par des experts en radiologie. Cette nouvelle base de données vise à améliorer la performance des algorithmes actuels de détection et de classification des masses mammaires, tout en soutenant le développement de nouvelles approches basées sur l'apprentissage profond et d'autres techniques avancées d'intelligence artificielle.

La construction de cette base de données repose sur une méthodologie rigoureuse incluant plusieurs étapes clés. Nous avons d'abord rassemblé des mammographies numériques provenant de diverses sources cliniques, en veillant à inclure une large gamme de cas et de conditions pathologiques. Chaque image a ensuite été annotée par au moins deux experts en radiologie afin d'assurer la précision et la fiabilité des annotations. Des techniques de prétraitement des images ont été appliquées pour améliorer leur qualité et faciliter une analyse ultérieure. Enfin, des fichiers au format JSON et CSV contenant les annotations et métadonnées ont été créés pour assurer la compatibilité avec les plateformes d'apprentissage automatique.

Cette nouvelle base de données présente plusieurs avantages et innovations par rapport aux bases de données existantes. Elle offre une précision d'annotation inégalée grâce à la validation par des experts, une diversité accrue des cas représentés et une compatibilité avec les formats et outils modernes utilisés dans la recherche en apprentissage automatique. En outre, cette base de données intègre des techniques de prétraitement avancées qui renforcent la qualité des images et facilitent leur utilisation pour le développement et l'évaluation des algorithmes de détection et de classification des masses mammaires.

Un des aspects novateurs de cette base de données est son origine algérienne, ce qui en fait la première base de données de mammographie numérique en Algérie, en Afrique du Nord et en Afrique. Cette particularité offre la possibilité d'explorer des axes de recherche spécifiques, tels que l'impact des conditions géographiques et des habitudes de vie sur le risque de cancer du sein. En analysant ces facteurs, nous pouvons mieux comprendre les influences environnementales et culturelles sur la prévalence et la présentation du cancer du sein.

Le reste de ce chapitre est organisé de la manière suivante : nous commencerons par une discussion approfondie sur les méthodes de collecte et d'annotation des données. Ensuite, nous examinerons les techniques de prétraitement mises en œuvre pour optimiser les images mammographiques. Nous présenterons ensuite la structure et le format de la base de données, suivis d'une évaluation des performances des algorithmes utilisant cette nouvelle ressource. Enfin, nous conclurons par une réflexion sur les implications et les perspectives futures de notre travail.

1. La Base de Données LAMIS-DMDB : Méthodes et Matériels

Dans cette section, nous présentons les matériaux et les méthodes employés pour développer un nouveau jeu de données complet intitulé "LAMIS- Base de Données de Mammographie Numérique pour le Cancer du Sein (LAMIS-DMDB)". Ce développement a été motivé par la nécessité d'améliorer la détection et la classification du cancer du sein par l'implémentation d'algorithmes avancés ML et DL

1.1.Acquisition de la Base de Données LAMIS-DMDB

La base de données LAMIS-DMDB représente une collection exhaustive de mammographies numériques en champ complet (FFDM), recueillies sur une période de cinq ans à partir de deux sources algériennes distinctes. La première source de données provient du Centre de Radiologie et d'Imagerie Médicale (ALRAZI) à Oran, où les examens ont été collectés et stockés entre janvier 2017 et septembre 2018. La seconde source est le Centre de Radiologie et d'Imagerie Médicale (RIM) à Tébessa, qui a fourni les examens archivés de septembre 2018 à décembre 2021. Pour garantir une haute qualité et une précision des données, toutes les images et les rapports associés, comprenant les avis des radiologues, ont été téléchargés à partir du système d'archivage et de communication d'images (PACS) de ces centres. Ce système permet une gestion centralisée et sécurisée des données médicales, assurant ainsi leur intégrité et leur accessibilité pour les chercheurs. L'équipement d'acquisition utilisé pour recueillir les mammographies est un mammographe GIOTO 3DL IMS, équipé de deux détecteurs en sélénium. Le premier détecteur a des dimensions de 24×30 cm, tandis que le second mesure 18×24 cm. Ces détecteurs offrent une résolution d'image de 3328×4084 pixels, avec une taille de pixel de 85 micromètres (μm). De plus, les images sont capturées avec une

profondeur de 32 bits par pixel (4 octets par pixel), garantissant une qualité d'image optimale pour une analyse détaillée.

1.2.L'importance du développement de la base de données

La création d'une nouvelle base de données sur le cancer du sein au format FFDM, telle que proposée par LAMIS-DMDB, revêt une importance cruciale pour plusieurs raisons. Cette base de données peut avoir un impact significatif sur l'avancement de la recherche sur le cancer du sein, en particulier dans le domaine des systèmes d'intelligence artificielle et du diagnostic assisté par ordinateur. Ses avantages sont nombreux :

1. Renforcement de la recherche : L'accès à une nouvelle base de données diversifiée offre aux chercheurs l'opportunité de mener des études approfondies sur le cancer du sein au sein de la population nord-africaine. Cela peut contribuer à mieux comprendre la prévalence, les schémas et les caractéristiques spécifiques des cas de cancer du sein dans cette population particulière.
2. Développement de systèmes IA-DAO : L'IA a démontré un potentiel considérable pour assister les radiologues et les professionnels de la santé dans la détection et le diagnostic du cancer du sein. Pour élaborer des systèmes de DAO robustes, une grande base de données de haute qualité est nécessaire. La LAMIS-DMDB peut servir de ressource précieuse pour entraîner et valider des modèles IA axés sur la détection du cancer du sein en modalité FFDM.
3. Médecine personnalisée : En utilisant une base de données spécifique à une région comme la LAMIS-DMDB, les chercheurs peuvent identifier des facteurs de risque régionaux, des marqueurs génétiques et des réponses aux traitements. Ces connaissances pourraient aboutir à des stratégies de gestion du cancer du sein plus personnalisées et efficaces pour les individus en Afrique du Nord.
4. Évaluation des programmes de dépistage : La base de données peut contribuer à évaluer l'efficacité des programmes de dépistage du cancer du sein déjà en place en Afrique du Nord et à repérer les domaines nécessitant des améliorations. Cela pourrait entraîner une meilleure détection précoce et une réduction des taux de mortalité associés au cancer du sein.
5. Assurance qualité et standardisation : En créant une base de données standardisée, la LAMIS-DMDB peut être utilisée comme référence pour évaluer la performance de différents algorithmes IA-DAO et les comparer les uns aux autres. Cela favorisera la transparence et la fiabilité dans le développement des systèmes IA pour la détection du cancer du sein robuste.
6. Formation et Education : La base de données peut être utilisée à des fins éducatives, telles que la formation des étudiants en médecine, des résidents et des chercheurs en IA dans le domaine du diagnostic du cancer du sein. Elle offre des exemples concrets pour l'enseignement et l'apprentissage pratique.
7. Collaboration et impact mondial : Le partage de la base de données au sein de la communauté de recherche peut favoriser la collaboration entre des experts de diverses régions, conduisant à une compréhension plus complète du cancer du sein dans le monde. Cela peut également attirer l'attention et le soutien international pour les initiatives de recherche en Afrique du Nord.

La création d'une nouvelle base de données comme LAMIS-DMDB est une entreprise complexe et chronophage qui nécessite des efforts et des ressources considérables. La création

d'une base de données de haute qualité et représentative pour la recherche sur le cancer du sein, en particulier au format FFDM, pose plusieurs défis qui prolongent le processus. Parmi les obstacles rencontrés, on trouve : la collecte des données, la protection de la vie privée et les considérations éthiques, l'annotation et la validation des données, la diversité et la représentativité des données, le nettoyage et le prétraitement des données, ainsi que la taille et la complexité de la base de données, sans oublier la maintenance à long terme.

Malgré ces défis, les efforts investis dans la création de LAMIS-DMDB ou de toute base de données similaires sont inestimables pour faire progresser la recherche sur le cancer du sein. Cette base de données sert de ressource fondamentale pour les chercheurs et les praticiens, leur permettant de développer de meilleurs outils diagnostiques, d'approfondir la compréhension des caractéristiques du cancer du sein et d'améliorer les résultats pour les patients.

1.3. Construction de LAMIS-DMDB

La phase d'acquisition est essentielle dans la création d'une base de données. Le flux de travail pour la construction de LAMIS-DMDB est illustré dans la Figure IV.3 et se compose de trois étapes : la collecte de données, le prétraitement et la classification.

La collecte des données consiste à télécharger les images ainsi que les rapports associés. Ces rapports sont rédigés conformément aux spécifications du système de rapport et de base de données d'imagerie mammaire du Collège américain de radiologie (ACR) (BI-RADS) et peuvent inclure d'autres notes. Le prétraitement des données comprend plusieurs tâches. La première consiste à segmenter les données en sous-ensembles en utilisant l'évaluation BI-RADS. La deuxième étape consiste à nettoyer la base de données en excluant les patients masculins, les rapports non vérifiés et les images incomplètes. En outre, les images classées en BI-RADS 0 (informations non concluantes) sont séparées car cette évaluation ne peut pas être considérée comme un diagnostic final. Les cas en BI-RADS 0 ne peuvent pas être traités comme normaux pour le dépistage. La troisième tâche vise à exclure tout contenu sensible des métadonnées dans les fichiers CSV afin de garantir que toutes les informations personnelles et privées des patients ne soient pas accessibles aux chercheurs. Une fois anonymisées, les métadonnées sont extraites et compilées dans un unique fichier CSV pour toutes les images de LAMIS-DMDB (Figure 3). Enfin, chaque fichier d'image est renommé comme suit :

```
`dataMG-PROC_P Numéro du patient _ID du patient _Vue gauche ou droite (CC ou MLO)
_date de l'examen`.
```

À partir de ce nom de fichier, les informations telles que l'identifiant du patient, le côté de l'image (gauche ou droite), les vues de l'image (CC ou MLO) et la date de l'examen peuvent être inférées sans avoir besoin d'ouvrir le fichier. Par exemple, l'image de la Figure 1 peut être trouvée dans le fichier :

```
`imagesdataMG-PROC_P347_71_R_CC_27_September_2018.dcm`.
```

Et celle de la Figure 2 dans un fichier presque similaire, remplaçant CC par MLO :

```
`imagesdataMG-PROC_P347_71_R_MLO_27_September_2018.dcm`.
```

La classification des données vise à préparer LAMIS-DMDB pour une utilisation par des systèmes intelligents. À cette fin, cinq classifications des données sont considérées : évaluation BI-RADS (5 classes), classification des anomalies (normale, bénigne ou maligne),

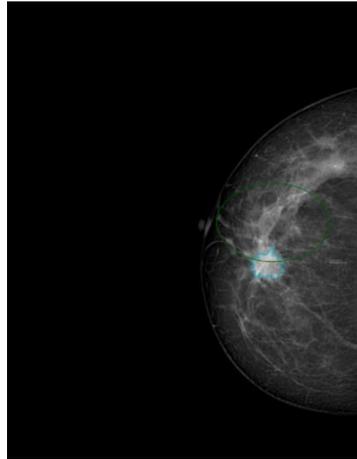


Figure IV. 2: Exemple annoté montrant la bordure d'une masse maligne hautement suspecte (couleur cyan) et une zone de structures mammaires à surveiller (couleur verte) d'une incidence craniocaudale (CC) de la base de données LAMIS-DMDB. Ceci concerne le même patient que la Figure IV. 2, ID 347, sein droit, classification de densité ACR II et BI-RADS V

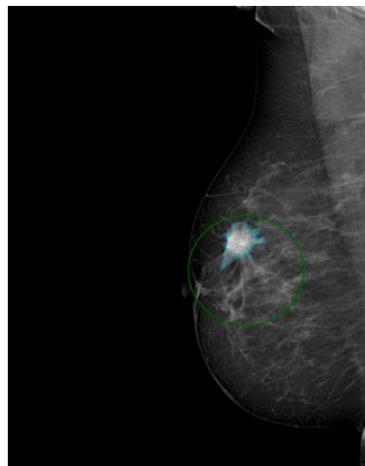


Figure IV. 1: Exemple annoté montrant la bordure d'une masse maligne hautement suspecte (couleur cyan) et une zone de structures mammaires à surveiller (couleur verte) d'une incidence médio-latérale oblique (MLO) de la base de données LAMIS-DMDB. Ceci concerne le même patient que la Figure IV. 1, ID 347, sein droit, classification de densité ACR II et BI-RADS V.

classification des lésions (masse, calcification, distorsion architecturale ou découverte multiple), classification de la densité (ACR1, ACR2, ACR3 ou ACR4) et une nouvelle classification hiérarchique suggérée ici, comme illustré dans la Figure IV 3. Ce système de classification novateur est basé sur la relation logique entre tous les diagnostics possibles d'une image. Il a été créé en collaboration avec les experts médicaux du projet pour une meilleure organisation et classification des données. Ce système de classification multifacette de LAMIS-DMDB constitue un avantage significatif par rapport aux ensembles de données existants sur le cancer du sein tels que DDSM ou d'autres.

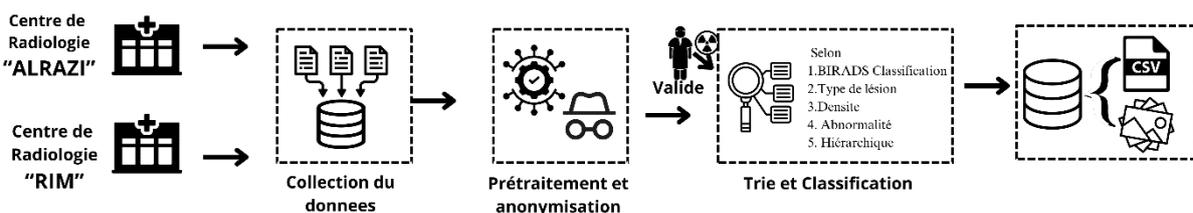


Figure IV. 3: Processus de construction de la base de données LAMIS-DMDB

LAMIS-DMDB se distingue par son utilisation efficace du format FFDM, dépassant ainsi la dépendance de DDSM aux films. Bien que INbreast adopte également le FFDM, LAMIS-DMDB se distingue par une augmentation significative du nombre d'images et de la diversité des cas. En outre, comparativement à des ensembles de données tels que MIAS et BrancoWeb, LAMIS-DMDB se positionne clairement comme une option supérieure. Son avantage distinct réside dans l'adoption du format FFDM, ce qui le distingue de MIAS et BrancoWeb qui utilisent des formats de film. Les chercheurs ont désormais accès à une ressource complète qui non seulement rationalise l'analyse des données, mais encourage également l'exploration et la découverte dans le domaine complexe de la recherche sur le cancer du sein. La prochaine section fournira plus de détails sur les métadonnées de LAMIS-DMDB.

1.4.Métadonnées de LAMIS-DMDB

Les métadonnées pour chaque image de la base de données LAMIS-DMDB sont consignées dans des fichiers CSV associés. Les fichiers DICOM contiennent des informations cruciales telles que l'âge du patient, la date de l'examen et l'identifiant (ID) du patient. De plus, le rapport inclut des détails sur la catégorie densité, le côté du sein examiné (gauche ou droit), la direction de l'acquisition (CC ou MLO), ainsi que des descriptions des anomalies détectées, le cas échéant (pour chaque anomalie, cela peut inclure : type, emplacement et distribution) et l'évaluation BI-RADS.

Les informations relatives au BI-RADS sont organisées en cinq fichiers CSV distincts, en fonction de l'évaluation BI-RADS. Pour le fichier CSV du BI-RADS I, il existe quatre classes ACR basées sur le degré de calcification : ACR1, ACR2, ACR3 et ACR4. Ce fichier CSV contient les informations suivantes : numéro du patient, date de l'examen, densité du tissu, identifiant du patient, côté du sein (gauche ou droit), vues (CC ou MLO), évaluation BI-RADS, âge du patient et adresse du fichier (c'est-à-dire le chemin d'accès aux fichiers d'image).

Pour les évaluations BI-RADS II et III, le fichier CSV inclut trois types de descriptions : une pour les masses, une autre pour les calcifications et une troisième pour les anomalies ou observations multiples. Pour le BI-RADS IV, le fichier CSV est également divisé en trois catégories : la première concerne les masses, la deuxième traite des distorsions architecturales et la troisième couvre les observations multiples. Enfin, le fichier CSV pour les évaluations BI-RADS V contient également des informations sur les masses, les calcifications et les observations multiples. De plus, les fichiers CSV peuvent comporter d'autres attributs, tels que la marge de la masse, la forme de la masse, le type de calcification, la distribution de la calcification, ainsi que des détails concernant l'anomalie (emplacement et distribution) et le chemin d'accès aux fichiers d'image. Les dernières étapes du diagramme illustré dans la Figure IV.3 représentent les processus de préparation des fichiers CSV décrits. Ainsi, le système de métadonnées de LAMIS-DMDB permet une organisation structurée et complète des données de mammographie, facilitant ainsi l'analyse et la recherche approfondie dans le domaine du cancer du sein et la radiologie en général.

1.5.Description de la LAMIS-DMDB

LAMIS-DMDB est une base de données organisée spécialement conçue pour stocker et gérer les informations relatives au cancer du sein chez les femmes. La LAMIS-DMDB contient des résultats répartis en cinq catégories : 914 mammographies normales, 802 masses ou

nodules, 196 calcifications, 4 distorsions architecturales et 300 images présentant des anomalies multiples.

Les cas asymétriques associés au BI-RADS III ont été supprimés de la base de données. Cela représente un total de 2216 images, dont 2080 images incluant les vues CC et MLO des seins gauche et droit (520 patientes bilatérales), 84 images provenant de 42 cas de patientes ayant subi une mastectomie unilatérale, et 56 images de 28 patientes présentant deux seins, mais un seul étant classé comme BI-RADS III. La base de données structurée offre un accès à des informations relatives aux cas bénins, malins et normal. Les algorithmes d'IA peuvent être formés sur les données de la LAMIS-DMDB pour identifier des motifs et effectuer des prédictions basées sur les images des patientes, les rapports de pathologie et les informations diagnostiques de différentes manières. Par conséquent, la LAMIS-DMDB se distingue comme un outil précieux pour la recherche et le développement de technologies de diagnostic assistées par l'IA, fournissant une base de données solide et variée pour la communauté scientifique et médicale. La Figure IV.4 illustre les différentes distributions et organisation de LAMIS-DMDB.

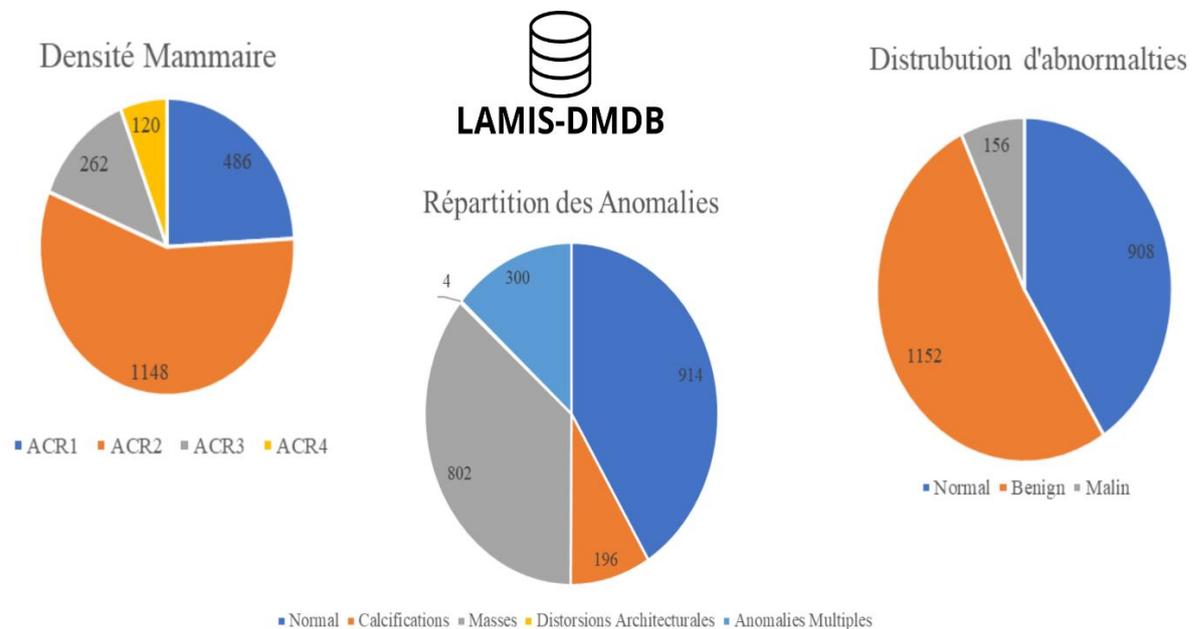


Figure IV. 4: Statistique de la base de données LAMIS-DMDB

Ce travail fait partie d'un projet de recherche intitulé : "IA pour le Service de Détection du Cancer du Sein", approuvé en Algérie par deux ministères : le Ministère de la Santé et de la Population et le Ministère de l'Enseignement Supérieur et de la Recherche Scientifique. La base de données LAMIS-DMDB est disponible pour les chercheurs qui souhaitent l'utiliser pour leurs travaux. Pour accéder à cette base de données, les chercheurs doivent soumettre une demande à l'adresse suivante : <https://rb.gy/3h2zry>. Ce projet vise à améliorer la détection et le diagnostic du cancer du sein en utilisant des algorithmes d'intelligence artificielle avancés, contribuant ainsi à l'amélioration des soins de santé et à l'innovation scientifique en Algérie et au-delà.

2. LAMIS-DMDB pour les Méthodes de ML et DL

Cette section vise non seulement à valider la pertinence de la LAMIS-DMDB pour l'entraînement de modèles ML et DL, mais également à démontrer son potentiel en tant que ressource essentielle pour les chercheurs en IA appliquée à la santé. Plutôt que de se concentrer sur le développement de modèles de classification précis, cette étude s'attache à vérifier si la LAMIS-DMDB répond aux exigences nécessaires pour former des modèles ML et DL. La disponibilité d'une base de données exhaustive sur le cancer du sein comme la LAMIS-DMDB, constitue une pierre angulaire pour le développement de nouveaux systèmes intelligents de diagnostic. En offrant une base de données riche et varié, elle permet aux chercheurs de faire avancer leurs projets en IA, en facilitant l'entraînement et la validation de nouveaux algorithmes. Pour illustrer la capacité des algorithmes d'apprentissage profond à exploiter la LAMIS-DMDB, nous proposons deux stratégies de classification par DL. La première stratégie consistait à entraîner un modèle CNN à partir de zéro pour classer les images de mammographie en catégories binaires : normales ou anormales. De plus, une autre expérience a classé les images de mammographie en trois classes : normale, bénigne et maligne. La deuxième stratégie a utilisé le transfert d'apprentissage, où des modèles pré-entraînés ont été adaptés pour classer les images dans les trois catégories : normale, bénigne et maligne.

2.1.Stratégies de Classification par Apprentissage Profond

Pour démontrer la capacité des algorithmes DL à exploiter la base de données LAMIS-DMDB, nous avons exploré et testé deux expériences de classification distinctes. Ces expériences visent à valider l'utilisation de la LAMIS-DMDB pour entraîner des modèles DL et à montrer son potentiel en tant que ressource essentielle pour la recherche en intelligence artificielle appliquée à la santé.

2.1.1. Méthodes et Matériels

Lors de la première expérimentation, un modèle CNN est développé à partir de zéro pour différencier les images de mammographie normales de celles anormales. Ce processus comprend l'application de techniques de prétraitement des données afin d'améliorer la qualité des images et d'optimiser les performances du modèle. La Figure IV.5 illustre le flux de travail de cette approche, mettant en évidence les étapes de l'entraînement du modèle ainsi que les résultats de classification obtenus.

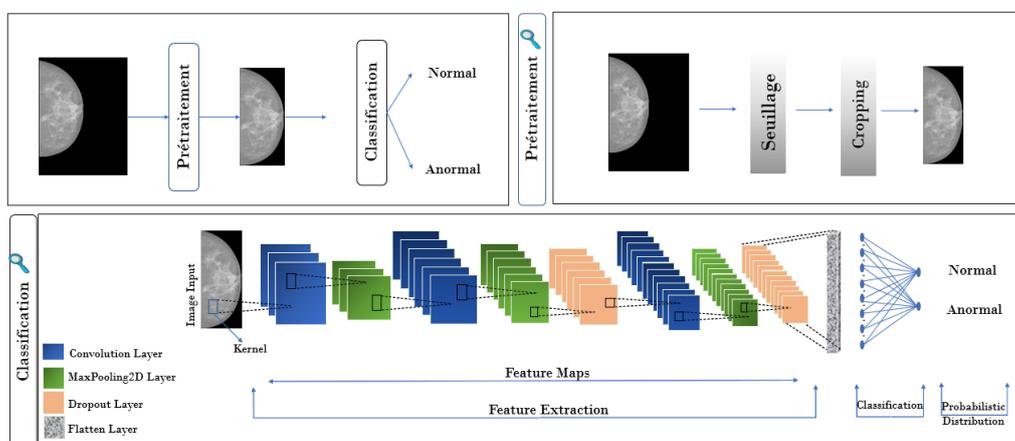


Figure IV. 5:Processus de Classification binaire

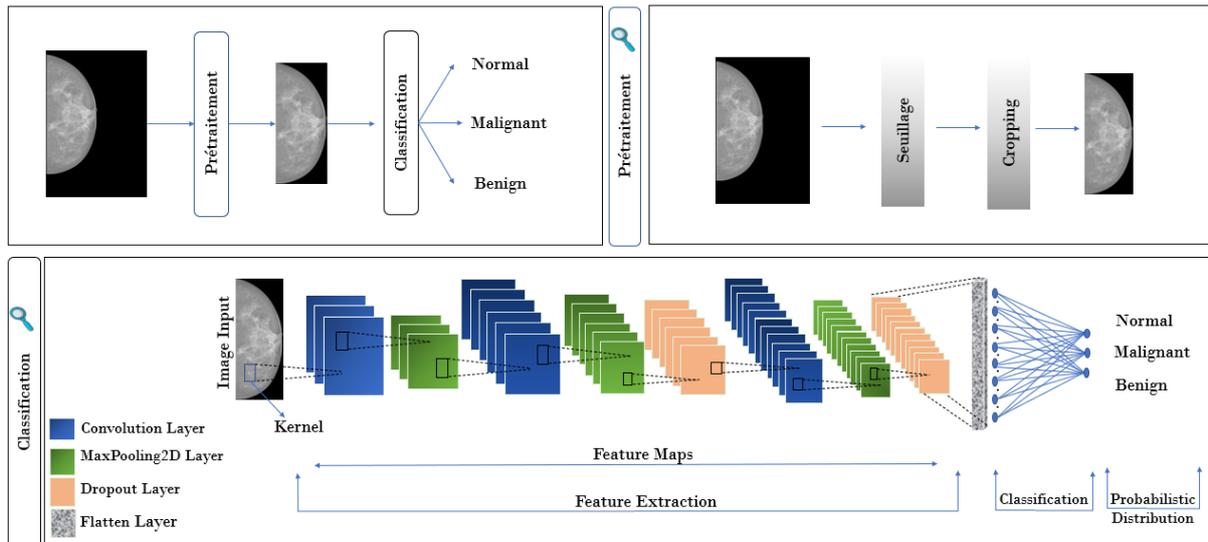


Figure IV. 6: Processus de Classification Multi class

La deuxième expérimentation étend cette approche en introduisant une classification à trois classes, où les images de mammographie sont classées comme normales, bénignes ou malignes. Cette méthode permet une différenciation plus fine des anomalies détectées dans les mammographies, offrant ainsi une meilleure précision diagnostique. La Figure IV. 6 illustre cette approche, montrant comment le modèle CNN est ajusté pour classer les trois classes ainsi que les résultats obtenus.

Les étapes de prétraitement sont les mêmes pour les deux stratégies envisagées. Tout d'abord, des techniques de seuillage sont utilisées pour extraire la zone du sein de chaque image de mammographie en niveaux de gris. Cette extraction est ensuite perfectionnée par des opérations morphologiques telles que l'érosion et la dilatation, ce qui améliore la qualité et la précision de la segmentation. Ensuite, les coordonnées exactes de la zone du sein sont établies en recadrant cette zone segmentée à partir de la mammographie originale en utilisant le masque obtenu lors de l'étape précédente. Afin d'assurer une cohérence dans le traitement des images, celles-ci, initialement de tailles variées, sont redimensionnées à une dimension de pixels standardisée pour la base de données.

Pour mettre en œuvre nos stratégies de classification des images de mammographie, nous avons conçu un modèle CNN. Ce modèle se compose d'une série de couches de convolution et de couches de max-pooling, suivies de couches denses. Les caractéristiques de chaque couche sont détaillées dans le tableau. Le modèle débute par une couche d'entrée qui reçoit les images de mammographie. La première couche de convolution utilise 32 filtres de taille 3x3 avec une fonction d'activation ReLU, suivie d'une couche de max pooling avec une taille de noyau de 2x2. Une deuxième couche de convolution est ensuite appliquée, avec 64 filtres de taille 3x3 et une activation ReLU, suivie d'une nouvelle couche de max pooling de taille 2x2. Pour éviter le surapprentissage, un dropout est appliqué par la suite. La troisième couche de convolution utilise 128 filtres de taille 3x3 avec une activation ReLU, suivie d'une couche de max pooling de taille 2x2. Ensuite, les données sont aplaties pour être traitées par les couches denses. La première couche dense comporte 128 unités avec une activation ReLU, suivie d'une couche dropout. Une deuxième couche dense, comprenant 32 unités avec une activation ReLU, est ensuite ajoutée. Enfin, la couche de sortie est définie en fonction de la nature de la classification.

Pour une classification binaire (N/AN), la couche de sortie comporte 1 unité avec une activation Sigmoid. En revanche, pour une classification à trois catégories (N/M/B), la couche de sortie comprend 3 unités avec une activation Softmax. Ce modèle a été élaboré pour illustrer l'efficacité de la LAMIS-DMDB en tant que ressource d'entraînement pour les algorithmes de apprentissage profond dans le domaine du diagnostic du cancer du sein.

Tableau IV. 1: Description des couches de modèle CNN

Couche	Type de couche	Filtres/Unités	Taille du noyau	Fonction d'activation
<i>Input layer</i>	Entrée	-	-	-
<i>Convolutional</i>	Convolutionnelle	32	(3,3)	<i>Relu</i>
<i>MaxPooling2D</i>	Max pooling	-	(2,2)	-
<i>Conv2D</i>	Convolutionnelle	64	(3,3)	<i>Relu</i>
<i>MaxPooling2D</i>	Max pooling	-	(2,2)	-
<i>Dropout</i>	Dropout	-	-	-
<i>Conv2D</i>	Convolutionnelle	128	(3,3)	<i>Relu</i>
<i>MaxPooling2D</i>	Max pooling	-	(2,2)	-
<i>Flatten</i>	Flatten	-	-	-
<i>Dense</i>	Dense	128	-	<i>Relu</i>
<i>Dropout</i>	Dropout	-	-	-
<i>Dense</i>	Dense	32	-	<i>Relu</i>
<i>Output layer (Binaire)</i>	Sortie	1	-	<i>Sigmoid</i>
<i>Output layer (multi-classes)</i>	Sortie	3	-	<i>Softmax</i>

2.1.2. Expérimentations et Résultats

Pour valider nos modèles de classification, nous avons employé un jeu de données constitué de 456 images de mammographie. Ces images, en deux dimensions et en niveaux de gris, proviennent de la base de données LAMIS-DMDB. Les algorithmes d'apprentissage profond ont été appliqués pour classer les images en fonction de la condition de l'anomalie. Toutes les images ont d'abord été soumises à l'étape de prétraitement. Les images prétraitées ont été réparties en trois ensembles : un ensemble d'entraînement destiné à optimiser les paramètres du modèle, un ensemble de validation utilisé pour ajuster les hyperparamètres, et un ensemble de test destiné à évaluer la performance du modèle final. La distribution des données se composait de 80 % pour l'entraînement, 10 % pour la validation et 10 % pour le test, garantissant qu'aucun chevauchement n'existait entre ces ensembles. Les hyperparamètres utilisés dans nos expériences sont les suivants : la taille des images est fixée à 224 pixels, l'optimiseur choisi est Adam, le nombre d'époques est de 30, la taille du batch est de 16, et le taux d'apprentissage est de 0,0001.

Les résultats des expérimentations ont montré que nos modèles CNN peut effectivement utiliser la base de données LAMIS-DMDB pour classifier les images de mammographie avec une précision élevé. Les métriques de performance, incluant la précision et le rappel, ont été déterminées pour évaluer la qualité des classifications binaires et multiclassées. Les résultats obtenus indiquent que la LAMIS-DMDB est une ressource précieuse pour l'entraînement de modèles d'apprentissage profond, confirmant son utilité pour le développement de systèmes intelligents de diagnostic du cancer du sein. Les courbes de perte présentées dans les Figures IV.7 et IV.8 démontrent l'absence de sous-apprentissage, ce qui indique que le modèle a réussi à apprendre à partir du jeu de données d'entraînement. De plus, ces courbes montrent qu'il n'y a pas de surapprentissage, car la courbe de perte d'entraînement diminue jusqu'à atteindre un point de stabilité proche de celle de la courbe de perte de validation. Cela signifie que les courbes de perte révèlent un bon ajustement. Les courbes de perte illustrées dans les Figures IV.8 et IV.9 démontrent qu'il n'y a pas de sous-apprentissage, ce qui indique que le modèle a réussi à apprendre à partir du jeu de données d'entraînement. De plus, les courbes de perte révèlent l'absence de surapprentissage, car la courbe de perte d'entraînement diminue jusqu'à atteindre un point de stabilité similaire à celui de la courbe de perte de validation. Cela signifie que les courbes de perte démontrent un bon ajustement. Les résultats obtenus pour la première stratégie de classification binaire montrent une précision de 65 %, tandis que la deuxième stratégie de classification multi-classes affiche une précision de 63 %. Ces résultats sont influencés par le nombre d'époques d'entraînement et la nécessité d'avoir plus de données pour entraîner efficacement un CNN à partir de zéro. Comme mentionné, l'objectif principal de cette section n'est pas d'améliorer la précision, mais de valider que la LAMIS-DMDB répond aux exigences nécessaires pour entraîner des modèles d'apprentissage profond.



Figure IV. 7: courbe de perte de classification binaire

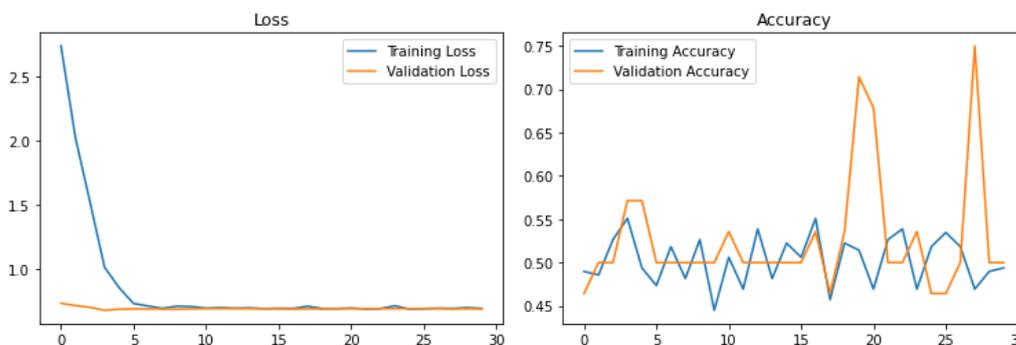


Figure IV. 8: courbe de perte de classification multi classes

2.2.Stratégies de Classification par Apprentissage par transfert

Dans les dernières années, le transfert d'apprentissage s'est imposé comme une technique efficace dans le cadre de l'apprentissage profond, permettant l'application de modèles préentraînés à de nouvelles tâches, même avec des données étiquetées limitées. Dans ce contexte, la base de données LAMIS-DMDB se révèle être une ressource précieuse, offrant une collection diversifiée et soigneusement sélectionnée d'images de mammographie. Cette sous-section explore l'intégration harmonieuse de la LAMIS-DMDB avec les algorithmes d'apprentissage par transfert.

2.2.1. Méthodes et Matériels

L'objectif principal de notre étude était d'explorer la faisabilité d'utiliser notre base de données LAMIS-DMDB en conjonction avec des techniques d'apprentissage par transfert pour la classification des images médicales. Notre méthodologie, représentée dans la Figure IV. 9, a débuté par l'extraction des images à partir des fichiers DICOM, suivie par l'extraction des organes à l'aide d'une série de méthodes de traitement d'image. Initialement, un flou gaussien a été appliqué pour lisser les images, suivi d'un seuillage binaire pour créer un masque binaire. Ce masque a été affiné à l'aide d'opérations morphologiques, spécifiquement l'érosion et la dilatation. Ensuite, la détection des contours a été utilisée pour recadrer avec précision l'organe à partir de l'image originale. Pour améliorer davantage la qualité de l'image, nous avons mis en œuvre la technique CLAHE pour améliorer le contraste.

Les modèles VGG16, ResNet50 et EfficientNetB7 ont été sélectionnés pour cette étude en raison de leurs architectures variées et de leurs performances démontrées dans les tâches de classification d'images. Le modèle VGG16 est reconnu pour sa simplicité et sa profondeur, ce qui le rend idéal pour capturer des caractéristiques à partir d'images. ResNet50 introduit le concept de connexions résiduelles, permettant l'entraînement de réseaux plus profonds sans dégradation des performances. EfficientNetB7 est choisi pour son équilibre entre précision et efficacité, grâce à une mise à l'échelle intégrée qui ajuste uniformément la profondeur, la largeur et la résolution du modèle.

En ce qui concerne la classification, nous avons utilisé ces modèles pré-entraînés, en les adaptant à notre problème spécifique en remplaçant leurs couches supérieures pour

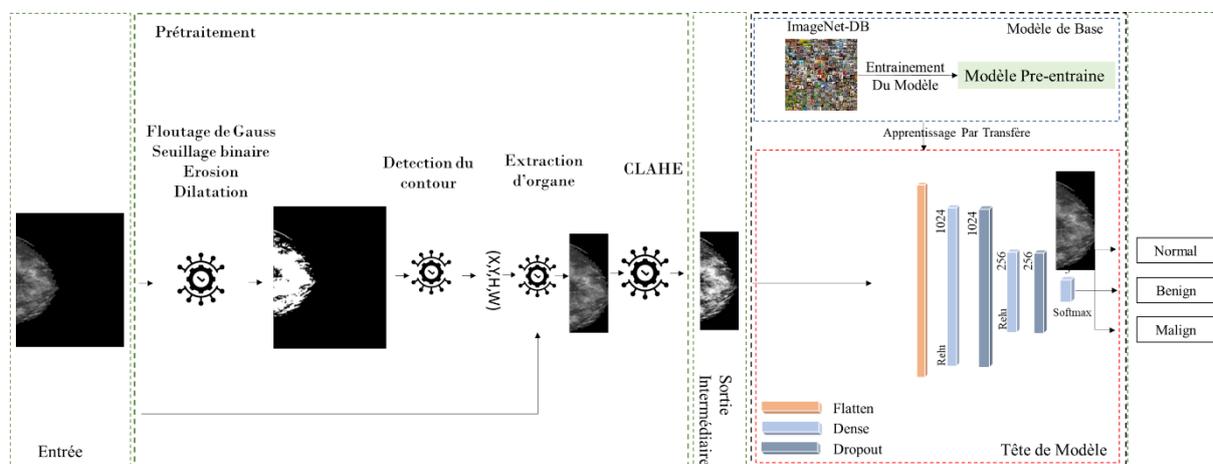


Figure IV. 9:Processus détaillé de classification de mammographie avec Apprentissage par Transfer

correspondre au nombre de classes dans notre jeu de données LAMIS-DMDB. Le fine-tuning de ces modèles a impliqué le dégel progressif des couches et l'ajustement des poids en utilisant l'optimiseur Adam avec un taux d'apprentissage initial de 0,001, ajusté en fonction des tendances de perte de validation. Chaque modèle a été entraîné pendant un nombre fixe d'époques pour assurer une évaluation cohérente

Les performances du modèle ont été évaluées à l'aide de mesures telles que la précision, le rappel, le score F1 et la matrice de confusion, permettant une évaluation complète des performances de classification sur différentes catégories d'images médicales. Cette approche visait à démontrer l'applicabilité et l'efficacité de l'apprentissage par transfert dans l'utilisation du jeu de données LAMIS-DMDB pour les tâches de classification d'images médicales.

2.2.2. Expérimentations et Résultats

Pour valider nos processus, nous avons employé un ensemble de données constitué de 456 images mammographiques provenant de notre base de données LAMIS-DMDB, réparties en 152 images pour chaque catégorie : normal, malin et bénin. Nous avons comparé les performances de trois modèles pré-entraînés (EfficientNetB7, ResNet50 et VGG160) dans trois scénarios expérimentaux différents :

- **Scénario 1** : Entraînement sur l'image complète : Les modèles ont été entraînés sur l'ensemble des images mammographiques complètes, sans recours à des techniques d'augmentation de données.
- **Scénario 2** : Entraînement sur l'image recadrée (sans augmentation) : Les modèles ont été entraînés sur des images mammographiques recadrées, sans appliquer de techniques d'augmentation de données.
- **Scénario 3** : Entraînement sur l'image recadrée (avec augmentation): Les modèles ont été entraînés sur des images mammographiques recadrées, avec l'application de techniques d'augmentation de données telles que la rotation, le retournement et le redimensionnement.

Chaque modèle pré-entraîné, initialisé avec des poids pré-entraînés sur ImageNet, a été adapté à notre tâche de classification à trois classes en remplaçant les couches supérieures. L'affinage des modèles impliquait l'ajustement des poids des couches supérieures en utilisant l'optimiseur Adam avec un taux d'apprentissage initial de 0,001.

Tableau IV. 2: Performance des modèles dans les différents scénarios

Modèle	Scénario	Accuracy	F1 Score	Recall	Précision
VGG16	1	0.58	0.58	0.58	0.62
	2	0.46	0.44	0.45	0.54
	3	0.78	0.78	0.78	0.79
ResNet50	1	0.63	0.62	0.63	0.62
	2	0.44	0.43	0.44	0.43
	3	0.74	0.74	0.74	0.75
EfficientNetB7	1	0.65	0.64	0.65	0.65
	2	0.52	0.53	0.52	0.54
	3	0.83	0.83	0.83	0.83

L'évaluation expérimentale comparait la performance des modèles pré-entraînés — VGG16, ResNet50 et EfficientNetB7 — sur un sous-ensemble équilibré de la base de données LAMIS-DMDB à travers différents scénarios expérimentaux. Ces scénarios différaient par la configuration des bases de données et les techniques d'augmentation de données, permettant ainsi d'évaluer leur impact sur la performance des modèles dans la classification des images médicales. Les résultats sont présentés dans le tableau de performance (Tableau IV.2) et la Figure IV.10, qui illustre les courbes de perte et de précision (Accuracy) pour les modèles pré-entraînés VGG16, ResNet50 et EfficientNetB7 dans différents scénarios expérimentaux.

Les modèles ont montré des performances variables selon les scénarios. Généralement, Le Scénario 3, qui intégrait une augmentation de la base de données, a systématiquement surpassé les Scénarios 1 et 2 pour l'ensemble des modèles. Le Scénario 2, qui utilisait des images rognées sans augmentation, présentait généralement des performances inférieures par rapport au Scénario 1 et surtout au Scénario 3, soulignant ainsi l'importance essentielle de l'augmentation des données pour améliorer la performance des modèles dans les tâches de classification d'images médicales. Le Scénario 1, utilisant des images complètes sans augmentation, montrait des performances modérées, indiquant que bien que les images complètes fournissent plus de contexte, l'augmentation affine encore davantage la capacité du modèle à généraliser à travers diverses conditions d'imagerie médicale.

Les résultats ont mis en lumière l'impact significatif de la configuration de la base de données et des techniques d'augmentation sur les performances de classification. Les modèles entraînés avec des données augmentées dans le Scénario 3 ont régulièrement obtenu une précision et un rappel supérieurs, soulignant ainsi l'importance de disposer de données diversifiées pour entraîner des classificateurs robustes destinés à l'analyse d'images médicales. L'augmentation de la base de données a permis une meilleure extraction des caractéristiques et a renforcé l'adaptabilité du modèle aux différentes conditions d'imagerie, entraînant une précision accrue et une meilleure capacité de généralisation.

Les résultats suggèrent qu'EfficientNetB7, particulièrement dans le Scénario 3 avec données augmentées, émerge comme la configuration optimale du modèle, offrant une précision et une précision supérieures par rapport aux autres scénarios. Les futures recherches devraient se concentrer sur l'exploration de techniques d'augmentation avancées et l'optimisation des hyperparamètres du modèle pour améliorer davantage les performances. Aborder des défis tels que le déséquilibre des classes et l'optimisation des architectures de modèles spécifiquement adaptées aux tâches d'imagerie médicale sera crucial pour faire progresser l'application de l'apprentissage profond dans les environnements cliniques.

En conclusion, les résultats expérimentaux ont démontré l'efficacité de l'apprentissage par transfert avec des modèles pré-entraînés pour les tâches de classification d'images médicales. En tirant parti de l'augmentation de la base de données et en choisissant des configurations de modèles adéquates, les chercheurs peuvent considérablement accroître la précision diagnostique et favoriser le développement d'applications d'imagerie médicale plus performantes.

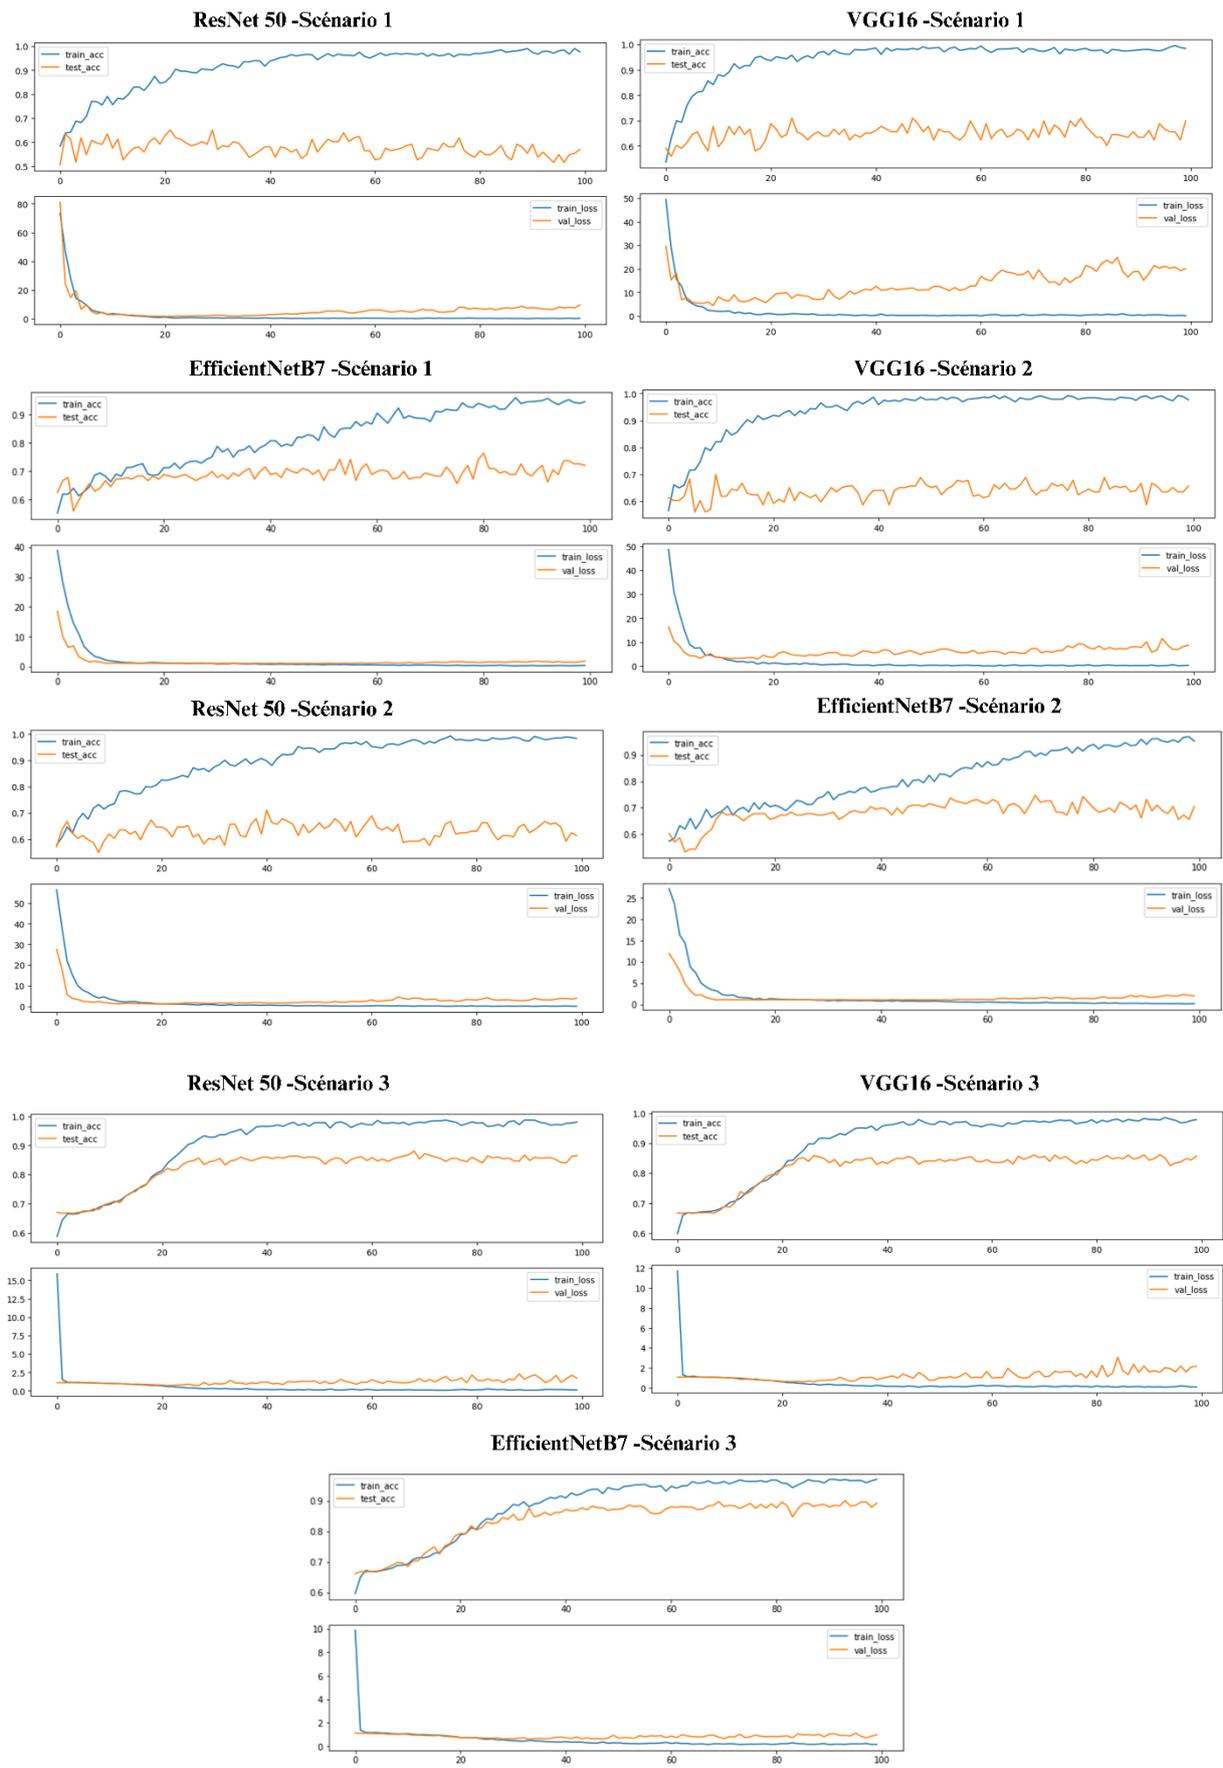


Figure IV. 10: Courbes de Perte et de Accuray pour tous les Modèles Pré-entraînés VGG16, ResNet50 et EfficientNetB7 sur Différents Scénarios Expérimentaux”

3. Plateforme Collaborative pour des Annotations Améliorées des Mammographies

Dans les situations où l'accès aux informations de référence est restreint, les collaborations avec des experts du domaine et d'autres chercheurs deviennent inestimables. Ces collaborations aident à identifier et rectifier collectivement les images potentiellement mal étiquetées, garantissant ainsi que l'exactitude et la fiabilité de la base de données. Pour ce faire, nous avons élaboré une plateforme dédiée, accessible à l'adresse (<https://mammo-annotator.com>), comme illustré à la Figure 11.

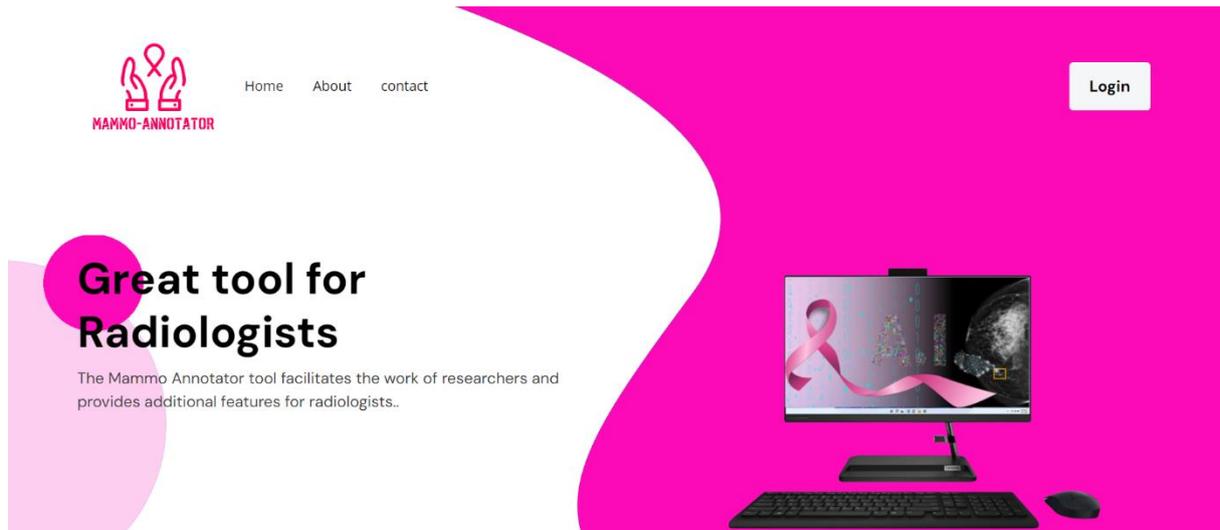


Figure IV. 11: Fenêtre d'accueil de la Plateforme d'annotation de LAMIS-DMDB

Cette plateforme permet aux radiologues de contribuer aux annotations d'images, augmentant ainsi la disponibilité des données étiquetées et réduisant la probabilité d'images potentiellement mal étiquetées, comme illustré à la Figure 12. En s'appuyant sur l'expertise des radiologues, la plateforme facilite la création d'annotations de haute qualité, essentielles pour l'entraînement et la validation des modèles d'apprentissage automatique en mammographie.

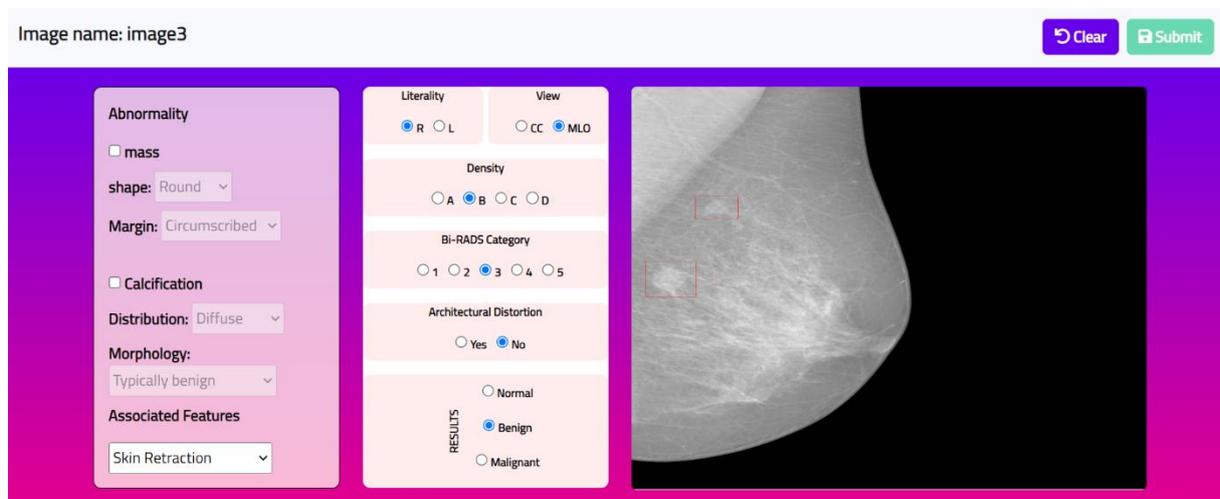


Figure IV. 12 : Fenêtre d'annotation de la Plateforme d'annotation de LAMIS-DMDB

L'un des principaux avantages de cette plateforme est son intégration avec notre système développé pour la détection et la segmentation du cancer du sein. Cette intégration agit comme une deuxième couche dans le processus d'interprétation et d'annotation des mammographies. Le système peut fournir des annotations préliminaires, que les radiologues peuvent ensuite examiner et corriger. Ce processus d'annotation supervisée améliore l'efficacité et l'exactitude des annotations en combinant l'analyse automatique avec la révision experte.

La nature collaborative de cette plateforme garantit qu'un groupe diversifié de radiologues peut examiner et annoter les images, aboutissant à un consensus qui améliore l'exactitude des données. Ce processus améliore non seulement la qualité des annotations, mais favorise également une approche collaborative pour établir des bases de données robustes et fiables destinées à des fins de recherche. De plus, la plateforme prend en charge un flux de travail d'annotation supervisée où les annotations initiales sont générées par notre système de détection et de segmentation. Les radiologues examinent ensuite ces annotations et apportent les corrections nécessaires. Cette approche accélère non seulement le processus d'annotation, mais aide également à affiner le système automatisé en lui fournissant des données corrigées pour un apprentissage et une amélioration continue.

En outre, nous avons appliqué notre système à la base de données LAMIS-DMDB, et quelques exemples d'images contenant les résultats de ces applications sont présentés aux Figure IV. 13. Ces images illustrent l'efficacité de notre système de détection et de segmentation, capable de fournir des annotations préliminaires avec précision.

En résumé, la plateforme sert d'outil essentiel pour améliorer le processus d'annotation en mammographie, en promouvant la collaboration entre les radiologues et en garantissant la création d'une base de données plus précise et plus complète pour les efforts de recherche en cours et futurs. L'intégration avec des systèmes automatisés de détection et de segmentation optimise encore le processus d'annotation, le rendant à la fois plus efficace et plus fiable.

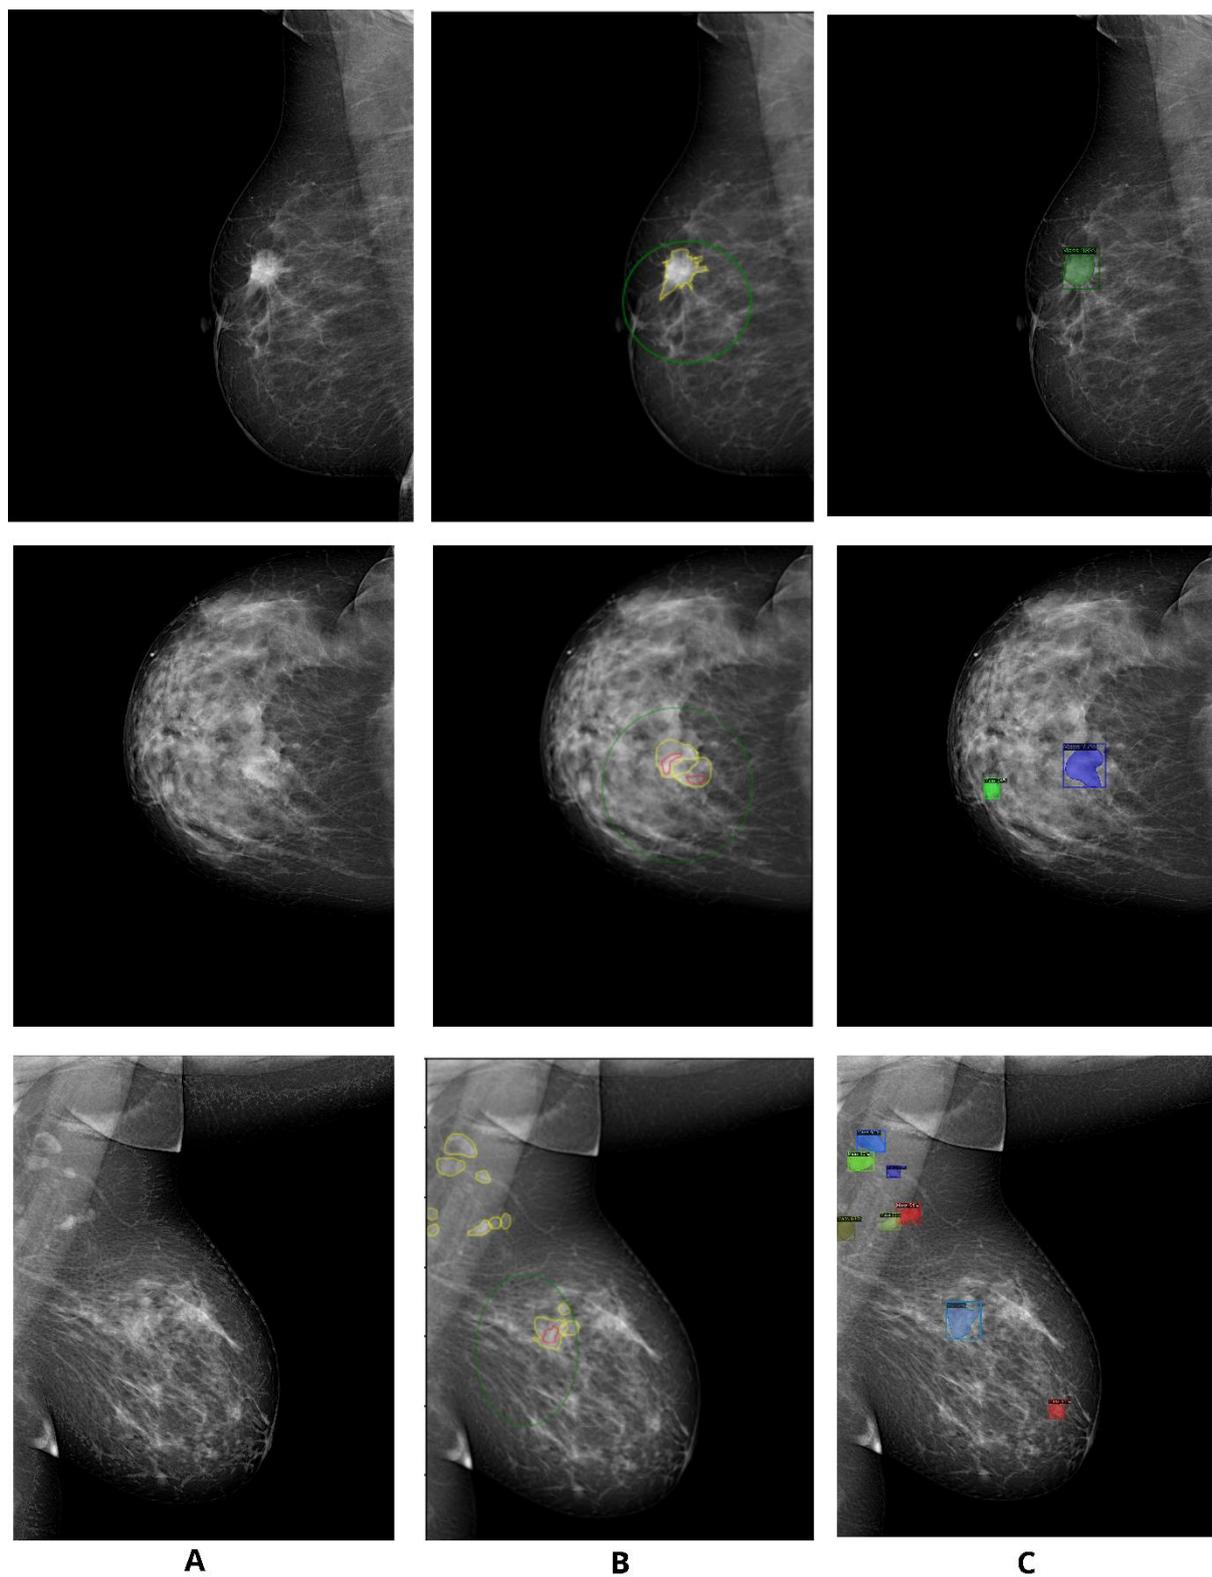


Figure IV. 13: Application de notre système en tant qu'outil d'annotation sur LAMIS-DMDB. A : Image de mammographie originale ; B : Mammographie avec annotation du radiologue ; C : Annotation ou résultat de notre système

4. Conclusion

En conclusion, la base de données LAMIS-DMDB est un outil novateur conçu spécifiquement pour la recherche sur le cancer du sein. Structurée selon diverses catégories, incluant la classification des anomalies malignes et bénignes, l'évaluation BI-RADS, et la classification de la densité mammaire, Elle offre aux chercheurs un accès facile à une large variété de données sur les patients, fournissant ainsi une vue d'ensemble complète de l'historique des diagnostics et des traitements.

Pour évaluer la faisabilité de cette base de données, nous l'avons mise à l'épreuve à travers deux tests de classification. Tout d'abord, elle a été employée avec un CNN pour classer les images en classification binaire (normal et anormal). Ensuite, nous avons utilisé l'apprentissage par transfert avec différents modèles pour classer les images en trois classes (normal, bénin, malin). Les résultats des deux tests confirment que notre base de données et les modèles utilisés sont capables de classer les images avec précision, attestant ainsi de leur compatibilité avec les algorithmes d'IA pour la recherche sur le cancer du sein.

L'acquisition et le traitement des données pour LAMIS-DMDB ont impliqué un processus long et exigeant, commencé en 2017 et poursuivi jusqu'en 2023, nécessitant un investissement considérable en temps et en efforts. Les étapes de curation et de prétraitement des données ont impliqué le nettoyage, la normalisation et la standardisation, garantissant ainsi la cohérence des données pour des prédictions précises et fiables. La comparaison avec d'autres bases de données de mammographie révèle que LAMIS-DMDB présente un nombre important de cas avec des images FFDM 2D étiquetées, la plus grande résolution par image et la plus grande quantité d'informations numériques archivées. La qualité des images constitue un atout essentiel, offrant des images de 32 bits par pixel avec une résolution de 3328×4084 pixels. En outre, elle inclut une gamme de métadonnées et de données cliniques, et offre un accès libre aux chercheurs et développeurs.

Nous espérons que la base de données LAMIS-DMDB sera une ressource précieuse pour les chercheurs en cancer du sein, facilitant des analyses avancées par des algorithmes d'IA, ce qui permet d'obtenir de meilleures perspectives de diagnostic et de traitement, tout en améliorant les résultats et la qualité de vie des patients.

Conclusion Générale & Perspective



Conclusion Générale & Perspective

Cette thèse a mené une analyse approfondie sur le diagnostic du cancer du sein, en mettant à profit des technologies et des approches de pointe dans le but de renforcer le dépistage précoce et d'optimiser les résultats des traitements. En commençant par un examen approfondi du contexte médical entourant le cancer du sein, nous avons souligné le rôle crucial de la mammographie en tant que modalité d'imagerie principale. Cette connaissance approfondie des concepts médicaux et des techniques d'imagerie a servi de fondement pour améliorer les systèmes de diagnostic assisté par ordinateur, spécialement conçus pour la détection du cancer du sein.

Une part importante de cette thèse a été dédiée à l'examen des systèmes de diagnostic assisté par ordinateur, en analysant diverses techniques de pointe pour la détection, la segmentation et la classification des masses mammaires. Cette revue a mis en lumière l'évolution et les avancées des approches basées sur l'intelligence artificielle, en mettant l'accent sur l'intégration des techniques d'apprentissage automatique et d'apprentissage profond pour améliorer la précision et l'efficacité du diagnostic.

Lors de la phase de mise en œuvre, nous avons focalisé nos efforts sur le développement et l'évaluation d'un nouveau système de diagnostic assisté par ordinateur dédié à la détection du cancer du sein. Notre approche a reposé sur l'intégration de Mask R-CNN et de l'apprentissage par transfert, afin d'améliorer la détection, la segmentation et la classification des masses mammaires à partir d'images mammographiques. Grâce à une expérimentation rigoureuse et à une évaluation approfondie des performances, nous avons validé l'efficacité de notre système, obtenant des taux élevés de précision et de rappel, ce qui souligne son potentiel d'application dans des contextes cliniques.

Une contribution majeure de cette thèse réside dans la création de la base de données LAMIS-DMDB, un référentiel structuré de données mammographiques enrichi par des annotations détaillées et des métadonnées. Cette base de données a permis de mener des recherches approfondies et de valider les algorithmes dédiés au diagnostic du cancer du sein. Le processus rigoureux de collecte, de nettoyage et de normalisation des données a garanti la fiabilité et l'utilisabilité du référentiel pour des études futures.

Dans le prolongement de ce travail, nous cherchons à intégrer nos méthodes développées dans des outils d'annotation et d'interprétation, dans le but d'optimiser les flux de travail cliniques liés au diagnostic du cancer du sein. En intégrant notre système de diagnostic assisté par IA dans des plateformes collaboratives, nous envisageons de fournir aux radiologues des analyses

préliminaires pour faciliter une prise de décision rapide tout en réduisant leur charge de travail. De plus, les fonctionnalités d'annotation semi-automatique de notre système permettent aux cliniciens d'annoter et de perfectionner efficacement les ensembles de données, ce qui favorise une amélioration continue de la précision et de l'efficacité du diagnostic.

À l'avenir, plusieurs avenues de recherche et de développement se dessinent :

- **Amélioration des Modèles d'Apprentissage Automatique** : Poursuivre l'exploration et l'affinement des modèles avancés d'apprentissage automatique pour renforcer continuellement la précision et la robustesse des systèmes de détection du cancer du sein.
- **Techniques Avancées** : Utiliser les mécanismes d'attention dans les transformeurs pour fournir des informations contextuelles pour différentes régions d'une image mammographique, améliorant ainsi la précision et l'efficacité des diagnostics.
- **Validation et Implémentation Cliniques** : Collaborer étroitement avec des experts cliniques afin de valider et intégrer les outils de diagnostic assisté par IA dans les flux de travail cliniques, en veillant à garantir leur efficacité et leur convivialité dans les environnements réels de soins de santé.
- **Considérations Éthiques et Réglementaires** : Aborder les implications éthiques et naviguer dans les cadres réglementaires concernant le déploiement de l'IA dans le diagnostic médical pour assurer la sécurité des patients et la conformité réglementaire.
- **Accessibilité Globale** : Promouvoir l'accessibilité et la scalabilité des solutions de diagnostic assisté par IA pour bénéficier aux populations diverses à l'échelle mondiale, en particulier dans les régions sous-desservies et à ressources limitées.

En conclusion, cette thèse contribue de manière significative aux avancées dans le domaine du diagnostic du cancer du sein en intégrant les technologies d'IA et des approches fondées sur l'exploitation des données. En abordant ces orientations futures, nous visons à favoriser l'innovation dans les soins du cancer du sein, ce qui entraîne finalement une amélioration des résultats pour les patients et une qualité de vie supérieure. L'intégration de nos méthodes développées dans des systèmes collaboratifs marque une étape décisive vers l'autonomisation des cliniciens et l'amélioration des capacités de diagnostic dans la lutte contre le cancer du sein.

Bibliographie



Bibliographie

1. Siegel RL, Miller KD, Fuchs HE, Jemal A (2021) Cancer Statistics, 2021. *CA Cancer J Clin* 71:7–33. <https://doi.org/10.3322/caac.21654>
2. Doi K (2007) Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics* 31:198–211. <https://doi.org/10.1016/j.compmedimag.2007.02.002>
3. Padhi S, Rup S, Saxena S, Mohanty F (2019) Mammogram Segmentation Methods: A Brief Review. In: 2019 2nd International Conference on Intelligent Communication and Computational Techniques (ICCT). IEEE, pp 218–223
4. Breast Cancer Risk Factors and Prevention Methods, <https://www.cdc.gov/breast-cancer/risk-factors/index.html>, Visite Le 19 avril 2024.
5. Gardezi SJS, Elazab A, Lei B, Wang T (2019) Breast Cancer Detection and Diagnosis Using Mammographic Data: Systematic Review. *J Med Internet Res* 21:e14464. <https://doi.org/10.2196/14464>
6. Nasser M, Yusof UK (2023) Deep Learning Based Methods for Breast Cancer Diagnosis: A Systematic Review and Future Direction. *Diagnostics* 13:161. <https://doi.org/10.3390/diagnostics13010161>
7. Barba D, León-Sosa A, Lugo P, et al (2021) Breast cancer, screening and diagnostic tools: All you need to know. *Crit Rev Oncol Hematol* 157:103174. <https://doi.org/10.1016/j.critrevonc.2020.103174>
8. Nakshatri H, Anjanappa M, Bhat-Nakshatri P (2015) Ethnicity-Dependent and -Independent Heterogeneity in Healthy Normal Breast Hierarchy Impacts Tumor Characterization. *Sci Rep* 5:13526. <https://doi.org/10.1038/srep13526>
9. Centers for Disease Control and Prevention C D C. What Does It Mean to Have Dense Breasts? https://www.cdc.gov/cancer/breast/basic_info/dense-breasts.htm. Accessed 13 Apr 2024
10. Destounis S V., Santacroce A, Arieno A (2020) Update on Breast Density, Risk Estimation, and Supplemental Screening. *American Journal of Roentgenology* 214:296–305. <https://doi.org/10.2214/AJR.19.21994>

11. Darlington AJ (2015) Anatomy of the Breast. In: Digital Mammography. Springer International Publishing, Cham, pp 3–10
12. Ellis H (2007) Anatomy of the breast. *Surgery (Oxford)* 25:251–253. <https://doi.org/10.1016/j.mpsur.2007.04.019>
13. Tse G, Tan PH, Schmitt F (2013) Anatomy and Physiology of the Breast. In: Fine Needle Aspiration Cytology of the Breast. Springer Berlin Heidelberg, Berlin, Heidelberg, pp 1–5
14. Geddes DT (2007) Inside the Lactating Breast: The Latest Anatomy Research. *J Midwifery Womens Health* 52:556–563. <https://doi.org/10.1016/j.jmwh.2007.05.004>
15. Hassiotou F, Geddes D (2013) Anatomy of the human mammary gland: Current status of knowledge. *Clinical Anatomy* 26:29–48. <https://doi.org/10.1002/ca.22165>
16. Asma Touil (2021) Fusion collaborative de classifieurs : application à la détection de pathologies en mammographie. Institut supérieur d'informatique et des techniques de communication
17. Wellings SR (1980) A Hypothesis of the Origin of Human Breast Cancer from the Terminal Ductal Lobular Unit. *Pathol Res Pract* 166:515–535. [https://doi.org/10.1016/S0344-0338\(80\)80248-2](https://doi.org/10.1016/S0344-0338(80)80248-2)
18. Shaikh K, Krishnan S, Thanki R (2021) Artificial Intelligence in Breast Cancer Early Detection and Diagnosis. Springer International Publishing, Cham
19. Centre Léon Bérard - 2022 Cancer du sein. <https://www.cancer-environnement.fr/fiches/cancers/cancer-du-sein/#>. Visite 17 avril 2024
20. Cdc (2023) What Are the Symptoms of Breast Cancer? <https://www.cdc.gov/breast-cancer/symptoms/index.html>, Visite 18 avril 2024
21. Gustalik J, Bartusik-Aebisher D, Aebisher D, Kaznowska E (2019) Imaging methods of early detection and screening for breast cancer. A review. *European Journal of Clinical and Experimental Medicine* 17:142–145. <https://doi.org/10.15584/ejcem.2019.2.6>
22. Mann RM, Hooley R, Barr RG, Moy L (2020) Novel approaches to screening for breast cancer. *Radiology* 297:266–285
23. Javaeed A (2018) Breast cancer screening and diagnosis: a glance back and a look forward. *Int J Community Med Public Health* 5:4997. <https://doi.org/10.18203/2394-6040.ijcmph20184605>
24. (2023) Mammographie - Comment se déroule une mammographie Ramsay Santé, <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/mammographie>, Visite 18 avril 2024
25. Imane O, Mohamed A, Lazhar RF, et al (2024) LAMIS-DMDB: A new full field digital mammography database for breast cancer AI-CAD researches. *Biomed Signal Process Control* 90:105823. <https://doi.org/10.1016/j.bspc.2023.105823>

26. Eberl MM, Fox CH, Edge SB, et al (2006) BI-RADS Classification for Management of Abnormal Mammograms. *The Journal of the American Board of Family Medicine* 19:161–164. <https://doi.org/10.3122/jabfm.19.2.161>
27. Boyd NF, Guo H, Martin LJ, et al (2007) Mammographic Density and the Risk and Detection of Breast Cancer. *New England Journal of Medicine* 356:227–236. <https://doi.org/10.1056/NEJMoa062790>
28. Loizidou K, Elia R, Pitris C (2023) Computer-aided breast cancer detection and classification in mammography: A comprehensive review. *Comput Biol Med* 153:106554. <https://doi.org/10.1016/j.compbiomed.2023.106554>
29. Alghaib HA, Scott M, Adhami RR (2016) An Overview of Mammogram Analysis. *IEEE Potentials* 35:21–28. <https://doi.org/10.1109/MPOT.2015.2396533>
30. Kopans DB, Swann CA, White G, et al (1989) Asymmetric breast tissue. *Radiology* 171:639–643. <https://doi.org/10.1148/radiology.171.3.2541463>
31. Arancibia Hernández PL, Taub Estrada T, López Pizarro A, et al (2016) Calcificaciones mamarias: descripción y clasificación según la 5.a edición BI-RADS. *Revista Chilena de Radiología* 22:80–91. <https://doi.org/10.1016/j.rchira.2016.06.004>
32. Loizidou K, Skouroumouni G, Nikolaou C, Pitris C (2022) Automatic Breast Mass Segmentation and Classification Using Subtraction of Temporally Sequential Digital Mammograms. *IEEE J Transl Eng Health Med* 10:1–11
33. J. Suckling (1994) The Mammographic Image Analysis Society Digital Mammogram Database. *Excerpta Medica International Congress* 1069:375–378
34. Popli MB, Teotia R, Narang M, Krishna H (2014) Breast Positioning during Mammography: Mistakes to be Avoided. *Breast Cancer (Auckl)* 8:BCBCR.S17617. <https://doi.org/10.4137/BCBCR.S17617>
35. Mračko A, Vanovčanová L, Cimrák I (2023) Mammography Datasets for Neural Networks—Survey. *J Imaging* 9:95. <https://doi.org/10.3390/jimaging9050095>
36. Lee RS, Gimenez F, Hoogi A, et al (2017) A curated mammography data set for use in computer-aided detection and diagnosis research. *Sci Data* 4:170177. <https://doi.org/10.1038/sdata.2017.177>
37. Michael Heath, Kevin Bowyer, Daniel Kopans, et al (2001) The Digital Database for Screening Mammography. In: M.J. Yaffe (ed) *Proceedings of the Fifth International Workshop on Digital Mammography*. Medical Physics Publishing, pp 212–218
38. Moreira IC, Amaral I, Domingues I, et al (2012) INbreast. *Acad Radiol* 19:236–248. <https://doi.org/10.1016/j.acra.2011.09.014>
39. Angel Guevara Lopez M, Ramos Pollán R, Miguel Franco-Valiente J (2012) BCDR: A BREAST CANCER DIGITAL REPOSITORY
40. Logan J, Kennedy PJ, Catchpoole D (2023) A review of the machine learning datasets in mammography, their adherence to the FAIR principles and the outlook for the future. *Sci Data* 10:595. <https://doi.org/10.1038/s41597-023-02430-6>

41. Halling-Brown MD, Warren LM, Ward D, et al (2021) OPTIMAM Mammography Image Database: A Large-Scale Resource of Mammography Images and Clinical Data. *Radiol Artif Intell* 3:e200103
42. Nguyen HT, Nguyen HQ, Pham HH, et al (2023) VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography. *Sci Data* 10:277. <https://doi.org/10.1038/s41597-023-02100-7>
43. Jeong JJ, Vey BL, Bhimireddy A, et al (2023) The EMory BrEast imaging Dataset (EMBED): A Racially Diverse, Granular Dataset of 3.4 Million Screening and Diagnostic Mammographic Images. *Radiol Artif Intell* 5:. <https://doi.org/10.1148/ryai.220047>
44. Miranda-Viana M, Fontenele RC, Nogueira-Reis F, et al (2023) DICOM file format has better radiographic image quality than other file formats: an objective study. *Braz Dent J* 34:150–157. <https://doi.org/10.1590/0103-6440202305499>
45. Prevedello LM, Halabi SS, Shih G, et al (2019) Challenges Related to Artificial Intelligence Research in Medical Imaging and the Importance of Image Analysis Competitions. *Radiol Artif Intell* 1:e180031. <https://doi.org/10.1148/ryai.2019180031>
46. Elyan E, Vuttipittayamongkol P, Johnston P, et al (2022) Computer vision and machine learning for medical image analysis: recent advances, challenges, and way forward. *Artificial Intelligence Surgery*. <https://doi.org/10.20517/ais.2021.15>
47. Hassan NM, Hamad S, Mahar K (2022) Mammogram breast cancer CAD systems for mass detection and classification: a review. *Multimed Tools Appl* 81:20043–20075. <https://doi.org/10.1007/s11042-022-12332-1>
48. Al-Antari MA, Al-Masni MA, Kim T-S (2020) Deep Learning Computer-Aided Diagnosis for Breast Lesion in Digital Mammogram. *Adv Exp Med Biol* 59–72. https://doi.org/10.1007/978-3-030-33128-3_4
49. Maitra IK, Nag S, Bandyopadhyay SK (2012) Technique for preprocessing of digital mammogram. *Comput Methods Programs Biomed* 107:175–188. <https://doi.org/10.1016/j.cmpb.2011.05.007>
50. Tripathy S, Swarnkar T (2020) Unified Preprocessing and Enhancement Technique for Mammogram Images. *Procedia Comput Sci* 167:285–292. <https://doi.org/https://doi.org/10.1016/j.procs.2020.03.223>
51. Zahoor S, Lali IU, Khan MA, et al (2021) Breast Cancer Detection and Classification using Traditional Computer Vision Techniques: A Comprehensive Review. *Current Medical Imaging Formerly Current Medical Imaging Reviews* 16:1187–1200. <https://doi.org/10.2174/1573405616666200406110547>
52. Tatikonda KC, Bhuma CM, Samayamantula SK (2018) The Analysis of Digital Mammograms Using HOG and GLCM Features. In: 2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT). IEEE, pp 1–7

53. Al-antari MA, Al-masni MA, Choi M-T, et al (2018) A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification. *Int J Med Inform* 117:44–54. <https://doi.org/10.1016/j.ijmedinf.2018.06.003>
54. Hamed G, Marey M, Amin SE, Tolba MF (2021) Automated Breast Cancer Detection and Classification in Full Field Digital Mammograms Using Two Full and Cropped Detection Paths Approach. *IEEE Access* 9:116898–116913. <https://doi.org/10.1109/ACCESS.2021.3105924>
55. Abdelhafiz D, Bi J, Ammar R, et al (2020) Convolutional neural network for automated mass segmentation in mammography. *BMC Bioinformatics* 21:192. <https://doi.org/10.1186/s12859-020-3521-y>
56. Michael E, Ma H, Li H, et al (2021) Breast Cancer Segmentation Methods: Current Status and Future Potentials. *Biomed Res Int* 2021:1–29. <https://doi.org/10.1155/2021/9962109>
57. Oliver A, Freixenet J, Martí J, et al (2010) A review of automatic mass detection and segmentation in mammographic images. *Med Image Anal* 14:87–110. <https://doi.org/10.1016/j.media.2009.12.005>
58. Patrício C, Neves JC, Teixeira LF (2024) Explainable Deep Learning Methods in Medical Image Classification: A Survey. *ACM Comput Surv* 56:1–41. <https://doi.org/10.1145/3625287>
59. Mahmood T, Li J, Pei Y, et al (2022) Breast lesions classifications of mammographic images using a deep convolutional neural network-based approach. *PLoS One* 17:e0263126. <https://doi.org/10.1371/journal.pone.0263126>
60. Ayana G, Dese K, Dereje Y, et al (2023) Vision-Transformer-Based Transfer Learning for Mammogram Classification. *Diagnostics* 13:178. <https://doi.org/10.3390/diagnostics13020178>
61. Soltani H, Bendib I, Haouam MY, Amroune M (2024) Advancements in Breast Cancer Diagnosis: A Comprehensive Review of Mammography Datasets, Preprocessing and Classification Techniques. *Acta Informatica Pragensia* 13:308–326. <https://doi.org/10.18267/j.aip.244>
62. de Nazaré Silva J, de Carvalho Filho AO, Corrêa Silva A, et al (2015) Automatic Detection of Masses in Mammograms Using Quality Threshold Clustering, Correlogram Function, and SVM. *J Digit Imaging* 28:323–337. <https://doi.org/10.1007/s10278-014-9739-3>
63. Chu J, Min H, Liu L, Lu W (2015) A novel computer aided breast mass detection scheme based on morphological enhancement and SLIC superpixel segmentation. *Med Phys* 42:3859–3869. <https://doi.org/10.1118/1.4921612>
64. Mohanty F, Rup S, Dash B, et al (2019) A computer-aided diagnosis system using Tchebichef features and improved grey wolf optimized extreme learning machine. *Applied Intelligence* 49:983–1001. <https://doi.org/10.1007/s10489-018-1294-z>

65. Dheeba J, Albert Singh N, Tamil Selvi S (2014) Computer-aided detection of breast cancer on mammograms: A swarm intelligence optimized wavelet neural network approach. *J Biomed Inform* 49:45–52. <https://doi.org/10.1016/j.jbi.2014.01.010>
66. Shen-Chuan Tai, Zih-Siou Chen, Wei-Ting Tsai (2014) An Automatic Mass Detection System in Mammograms Based on Complex Texture Features. *IEEE J Biomed Health Inform* 18:618–627. <https://doi.org/10.1109/JBHI.2013.2279097>
67. Dhahbi S, Barhoumi W, Zagrouba E (2015) Breast cancer diagnosis in digitized mammograms using curvelet moments. *Comput Biol Med* 64:79–90. <https://doi.org/10.1016/j.compbiomed.2015.06.012>
68. Chakraborty J, Midya A, Rabidas R (2018) Computer-aided detection and diagnosis of mammographic masses using multi-resolution analysis of oriented tissue patterns. *Expert Syst Appl* 99:168–179. <https://doi.org/10.1016/j.eswa.2018.01.010>
69. Eltoukhy MM, Elhoseny M, Hosny KM, Singh AK (2018) Computer aided detection of mammographic mass using exact Gaussian–Hermite moments. *J Ambient Intell Humaniz Comput*. <https://doi.org/10.1007/s12652-018-0905-1>
70. Dhahbi S, Barhoumi W, Kurek J, et al (2018) False-positive reduction in computer-aided mass detection using mammographic texture analysis and classification. *Comput Methods Programs Biomed* 160:75–83. <https://doi.org/10.1016/j.cmpb.2018.03.026>
71. Dhungel N, Carneiro G, Bradley AP (2015) Automated Mass Detection in Mammograms Using Cascaded Deep Learning and Random Forests. In: 2015 International Conference on Digital Image Computing: Techniques and Applications (DICTA). IEEE, pp 1–8
72. Al-masni MA, Al-antari MA, Park J-M, et al (2018) Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system. *Comput Methods Programs Biomed* 157:85–94. <https://doi.org/10.1016/j.cmpb.2018.01.017>
73. Jung H, Kim B, Lee I, et al (2018) Detection of masses in mammograms using a one-stage object detector based on a deep convolutional neural network. *PLoS One* 13:e0203355. <https://doi.org/10.1371/journal.pone.0203355>
74. Ribli D, Horváth A, Unger Z, et al (2018) Detecting and classifying lesions in mammograms with Deep Learning. *Sci Rep* 8:
75. Dhungel N, Carneiro G, Bradley AP (2017) A deep learning approach for the analysis of masses in mammograms with minimal user intervention. *Med Image Anal* 37:114–128. <https://doi.org/10.1016/j.media.2017.01.009>
76. Charan S, Khan MJ, Khurshid K (2018) Breast cancer detection in mammograms using convolutional neural network. In: 2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET). IEEE, pp 1–5
77. Shen L, Margolies LR, Rothstein JH, et al (2019) Deep Learning to Improve Breast Cancer Detection on Screening Mammography. *Sci Rep* 9:12495. <https://doi.org/10.1038/s41598-019-48995-4>

78. Aly GH, Marey M, El-Sayed SA, Tolba MF (2021) YOLO Based Breast Masses Detection and Classification in Full-Field Digital Mammograms. *Comput Methods Programs Biomed* 200:105823. <https://doi.org/10.1016/j.cmpb.2020.105823>
79. Zaitoun NM, Aqel MJ (2015) Survey on Image Segmentation Techniques. *Procedia Comput Sci* 65:797–806. <https://doi.org/10.1016/j.procs.2015.09.027>
80. Withey DJ, Koles ZJ (2007) Medical Image Segmentation: Methods and Software. In: 2007 Joint Meeting of the 6th International Symposium on Noninvasive Functional Source Imaging of the Brain and Heart and the International Conference on Functional Biomedical Imaging. IEEE, pp 140–143
81. Berber T, Alpkocak A, Balci P, Dicle O (2013) Breast mass contour segmentation algorithm in digital mammograms. *Comput Methods Programs Biomed* 110:150–159. <https://doi.org/10.1016/j.cmpb.2012.11.003>
82. Petrick N, Chan H-P, Sahiner B, Helvie MA (1999) Combined adaptive enhancement and region-growing segmentation of breast masses on digitized mammograms. *Med Phys* 26:1642–1654. <https://doi.org/10.1118/1.598658>
83. Punitha S, Amuthan A, Joseph KS (2018) Benign and malignant breast cancer segmentation using optimized region growing technique. *Future Computing and Informatics Journal* 3:348–358. <https://doi.org/10.1016/j.fcij.2018.10.005>
84. El Idrissi El Kaitouni S, Abbad A, Tairi H (2018) A breast tumors segmentation and elimination of pectoral muscle based on hidden markov and region growing. *Multimed Tools Appl* 77:31347–31362. <https://doi.org/10.1007/s11042-018-6089-z>
85. Makandar A, Halalli B (2016) Threshold Based Segmentation Technique for Mass Detection in Mammography. *J Comput (Taipei)* 472–478. <https://doi.org/10.17706/jcp.11.6.463-4712>
86. Singh N, Veenadhari S (2018) Breast Cancer Segmentation Using Global Thresholding and Region Merging. *International Journal of Computer Sciences and Engineering* 6:292–297. <https://doi.org/10.26438/ijcse/v6i12.292297>
87. Rampun A, Morrow PJ, Scotney BW, Winder J (2017) Fully automated breast boundary and pectoral muscle segmentation in mammograms. *Artif Intell Med* 79:28–41. <https://doi.org/10.1016/j.artmed.2017.06.001>
88. Chakraborty S, Bhowmik MK, Ghosh AK, Pal T (2016) Automated edge detection of breast masses on mammograms. In: 2016 IEEE Region 10 Conference (TENCON). IEEE, pp 1241–1245
89. B.N. BUM, Dr.M. M (2018) Mammogram Image Segmentation by Watershed Algorithm and Classification through k-NN Classifier. *Bonfring International Journal of Advances in Image Processing* 8:01–07. <https://doi.org/10.9756/BIJAIP.8352>
90. Podgornova Y, Sadykov S (2019) Comparative analysis of segmentation algorithms for the allocation of microcalcifications on mammograms. In: Proceedings of the V International conference Information Technology and Nanotechnology 2019. IP Zaitsev V.D., pp 121–127

91. Mohamed BA, Salem NM, Hadhoud MM, Seddik AF (2016) Automatic Segmentation and Classification of Masses from Digital Mammograms. *Advances in Image and Video Processing 4*. <https://doi.org/10.14738/aivp.44.2151>
92. Chen Z, Zwigelaar R (2012) A combined method for automatic identification of the breast boundary in mammograms. In: *2012 5th International Conference on BioMedical Engineering and Informatics*. IEEE, pp 121–125
93. Hu K, Gao X, Li F (2011) Detection of Suspicious Lesions by Adaptive Thresholding Based on Multiresolution Analysis in Mammograms. *IEEE Trans Instrum Meas* 60:462–472. <https://doi.org/10.1109/TIM.2010.2051060>
94. Angayarkanni SP, Kamal NB, Thangaiya RJ (2015) Dynamic graph cut based segmentation of mammogram. *Springerplus* 4:591. <https://doi.org/10.1186/s40064-015-1180-7>
95. Ramadijanti N, Barakbah A, Husna FA (2018) Automatic Breast Tumor Segmentation using Hierarchical K-means on Mammogram. In: *2018 International Electronics Symposium on Knowledge Creation and Intelligent Computing (IES-KCIC)*. IEEE, pp 170–175
96. Abdelhafiz D, Nabavi S, Ammar R, et al (2019) Residual Deep Learning System for Mass Segmentation and Classification in Mammography. In: *Proceedings of the 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics*. ACM, New York, NY, USA, pp 475–484
97. Hossain MS (2022) Microcalcification Segmentation Using Modified U-net Segmentation Network from Mammogram Images. *Journal of King Saud University - Computer and Information Sciences* 34:86–94. <https://doi.org/10.1016/j.jksuci.2019.10.014>
98. Sun H, Li C, Liu B, et al (2020) AUNet: attention-guided dense-upsampling networks for breast mass segmentation in whole mammograms. *Phys Med Biol* 65:055005. <https://doi.org/10.1088/1361-6560/ab5745>
99. Li H, Chen D, Nailon WH, et al (2018) Improved Breast Mass Segmentation in Mammograms with Conditional Residual U-Net. pp 81–89
100. Zeiser FA, da Costa CA, Zonta T, et al (2020) Segmentation of Masses on Mammograms Using Data Augmentation and Deep Learning. *J Digit Imaging* 33:858–868. <https://doi.org/10.1007/s10278-020-00330-4>
101. Tsochatzidis L, Koutla P, Costaridou L, Pratikakis I (2021) Integrating segmentation information into CNN for breast cancer diagnosis of mammographic masses. *Comput Methods Programs Biomed* 200:105913. <https://doi.org/10.1016/j.cmpb.2020.105913>
102. Salama WM, Aly MH (2021) Deep learning in mammography images segmentation and classification: Automated CNN approach. *Alexandria Engineering Journal* 60:4701–4709. <https://doi.org/10.1016/j.aej.2021.03.048>

103. Saffari N, Rashwan HA, Abdel-Nasser M, et al (2020) Fully Automated Breast Density Segmentation and Classification Using Deep Learning. *Diagnostics* 10:988. <https://doi.org/10.3390/diagnostics10110988>
104. Singh VK, Rashwan HA, Romani S, et al (2020) Breast tumor segmentation and shape classification in mammograms using generative adversarial and convolutional neural network. *Expert Syst Appl* 139:112855. <https://doi.org/10.1016/j.eswa.2019.112855>
105. N RR, R V, N E, Ramesh N (2021) Deeply supervised <sc>U-Net</sc> for mass segmentation in digital mammograms. *Int J Imaging Syst Technol* 31:59–71. <https://doi.org/10.1002/ima.22516>
106. Ren Y, Hou R, Kong D, et al (2019) Multiview mammographic mass detection based on a single shot detection system. In: Hahn HK, Mori K (eds) *Medical Imaging 2019: Computer-Aided Diagnosis*. SPIE, p 13
107. Nasser M, Yusof UK (2023) Deep Learning Based Methods for Breast Cancer Diagnosis: A Systematic Review and Future Direction. *Diagnostics* 13:161. <https://doi.org/10.3390/diagnostics13010161>
108. Berbar MA (2018) Hybrid methods for feature extraction for breast masses classification. *Egyptian Informatics Journal* 19:63–73. <https://doi.org/10.1016/j.eij.2017.08.001>
109. Vijayarajeswari R, Parthasarathy P, Vivekanandan S, Basha AA (2019) Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform. *Measurement* 146:800–805. <https://doi.org/10.1016/j.measurement.2019.05.083>
110. da Rocha SV, Braz Junior G, Silva AC, et al (2016) Texture analysis of masses malignant in mammograms images using a combined approach of diversity index and local binary patterns distribution. *Expert Syst Appl* 66:7–19. <https://doi.org/10.1016/j.eswa.2016.08.070>
111. Xie W, Li Y, Ma Y (2016) Breast mass classification in digital mammography based on extreme learning machine. *Neurocomputing* 173:930–941. <https://doi.org/10.1016/j.neucom.2015.08.048>
112. Danala G, Aghaei F, Heidari M, et al (2018) Computer-aided classification of breast masses using contrast-enhanced digital mammograms. In: Mori K, Petrick N (eds) *Medical Imaging 2018: Computer-Aided Diagnosis*. SPIE, p 91
113. Choi JY, Kim DH, Plataniotis KN, Ro YM (2016) Classifier ensemble generation and selection with multiple feature representations for classification applications in computer-aided detection and diagnosis on mammography. *Expert Syst Appl* 46:106–121. <https://doi.org/10.1016/j.eswa.2015.10.014>
114. Tahmasbi A, Saki F, Shokouhi SB (2011) Classification of benign and malignant masses based on Zernike moments. *Comput Biol Med* 41:726–735. <https://doi.org/10.1016/j.compbiomed.2011.06.009>

115. Rahmani Seryasat O, Haddadnia J (2018) Evaluation of a New Ensemble Learning Framework for Mass Classification in Mammograms. *Clin Breast Cancer* 18:e407–e420. <https://doi.org/10.1016/j.clbc.2017.05.009>
116. de Brito Silva TF, de Paiva AC, Silva AC, et al (2020) Classification of breast masses in mammograms using geometric and topological feature maps and shape distribution. *Research on Biomedical Engineering* 36:225–235. <https://doi.org/10.1007/s42600-020-00063-x>
117. Li H, Meng X, Wang T, et al (2017) Breast masses in mammography classification with local contour features. *Biomed Eng Online* 16:44. <https://doi.org/10.1186/s12938-017-0332-0>
118. Khan S, Hussain M, Aboalsamh H, Bebis G (2017) A comparison of different Gabor feature extraction approaches for mass classification in mammography. *Multimed Tools Appl* 76:33–57. <https://doi.org/10.1007/s11042-015-3017-3>
119. Hassan NM, Hamad S, Mahar K (2022) Mammogram breast cancer CAD systems for mass detection and classification: a review. *Multimed Tools Appl* 81:20043–20075. <https://doi.org/10.1007/s11042-022-12332-1>
120. Arevalo J, Gonzalez FA, Ramos-Pollan R, et al (2015) Convolutional neural networks for mammography mass lesion classification. In: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, pp 797–800
121. Altan G (2020) Deep Learning-based Mammogram Classification for Breast Cancer. *International Journal of Intelligent Systems and Applications in Engineering* 8:171–176. <https://doi.org/10.18201/ijisae.2020466308>
122. Wang J, Yang Y (2018) A context-sensitive deep learning approach for microcalcification detection in mammograms. *Pattern Recognit* 78:12–22. <https://doi.org/10.1016/j.patcog.2018.01.009>
123. Gnanasekaran VS, Joypaul S, Meenakshi Sundaram P, Chairman DD (2020) Deep learning algorithm for breast masses classification in mammograms. *IET Image Process* 14:2860–2868. <https://doi.org/10.1049/iet-ipr.2020.0070>
124. Müjdat Tiryaki V (2023) Mass segmentation and classification from film mammograms using cascaded deep transfer learning. *Biomed Signal Process Control* 84:104819. <https://doi.org/10.1016/j.bspc.2023.104819>
125. Ryspayeva M, Bria A, Marrocco C, et al (2024) Transfer learning in breast mass detection and classification. *J Ambient Intell Humaniz Comput* 15:3587–3602. <https://doi.org/10.1007/s12652-024-04835-6>
126. Chen Y, Zhang Q, Wu Y, et al (2019) Fine-Tuning ResNet for Breast Cancer Classification from Mammography. pp 83–96
127. Al-antari MA, Han S-M, Kim T-S (2020) Evaluation of deep learning detection and classification towards computer-aided diagnosis of breast lesions in digital X-ray

- mammograms. *Comput Methods Programs Biomed* 196:105584. <https://doi.org/10.1016/j.cmpb.2020.105584>
128. Falconi LG, Perez M, Aguila WG, Conci A (2020) Transfer Learning and Fine Tuning in Breast Mammogram Abnormalities Classification on CBIS-DDSM Database. *Advances in Science, Technology and Engineering Systems Journal* 5:154–165. <https://doi.org/10.25046/aj050220>
 129. Ansar W, Shahid AR, Raza B, Dar AH (2020) Breast Cancer Detection and Localization Using MobileNet Based Transfer Learning for Mammograms. *Intelligent Computing Systems* 11–21
 130. Zhang H, Wu R, Yuan T, et al (2020) DE-Ada*: A novel model for breast mass classification using cross-modal pathological semantic mining and organic integration of multi-feature fusions. *Inf Sci (N Y)* 539:461–486. <https://doi.org/10.1016/j.ins.2020.05.080>
 131. Hassan SA, Sayed MS, Abdalla MI, Rashwan MA (2020) Breast cancer masses classification using deep convolutional neural networks and transfer learning. *Multimed Tools Appl* 79:30735–30768. <https://doi.org/10.1007/s11042-020-09518-w>
 132. Barnett AJ, Schwartz FR, Tao C, et al (2021) A case-based interpretable deep learning model for classification of mass lesions in digital mammography. *Nat Mach Intell* 3:1061–1070. <https://doi.org/10.1038/s42256-021-00423-x>
 133. Zahoor S, Shoaib U, Lali IU (2022) Breast Cancer Mammograms Classification Using Deep Neural Network and Entropy-Controlled Whale Optimization Algorithm. *Diagnostics* 12:557. <https://doi.org/10.3390/diagnostics12020557>
 134. Sannasi Chakravarthy SR, Rajaguru H (2022) Automatic Detection and Classification of Mammograms Using Improved Extreme Learning Machine with Deep Learning. *IRBM* 43:49–61. <https://doi.org/10.1016/j.irbm.2020.12.004>
 135. Mudeng V, Jeong J, Choe S (2022) Simply Fine-Tuned Deep Learning-Based Classification for Breast Cancer with Mammograms. *Computers, Materials & Continua* 73:4677–4693. <https://doi.org/10.32604/cmc.2022.031046>
 136. Yu X, Ren Z, Guttery DS, Zhang Y-D (2023) DF-dRVFL: A novel deep feature based classifier for breast mass classification. *Multimed Tools Appl*. <https://doi.org/10.1007/s11042-023-15864-2>
 137. Sajid U, Khan RA, Shah SM, Arif S (2023) Breast cancer classification using deep learned features boosted with handcrafted features. *Biomed Signal Process Control* 86:105353. <https://doi.org/10.1016/j.bspc.2023.105353>
 138. He K, Gkioxari G, Dollár P, Girshick R (2017) Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV). IEEE, Los Alamitos, CA, USA, pp 2980–2988
 139. Wu Y, Kirillov A, Massa F, et al (2019) Detectron2

140. Soltani H, Amroune M, Bendib I, et al (2023) Breast lesions segmentation and classification in a two-stage process based on Mask-RCNN and Transfer Learning. *Multimed Tools Appl.* <https://doi.org/10.1007/s11042-023-16895-5>
141. Girshick R, Donahue J, Darrell T, Malik J (2013) Rich feature hierarchies for accurate object detection and semantic segmentation
142. Girshick R (2015) Fast R-CNN. <https://doi.org/https://doi.org/10.48550/arXiv.1504.08083>
143. Ren S, He K, Girshick R, Sun J (2015) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks
144. Pham V, Pham C, Dang T (2020) Road Damage Detection and Classification with Detectron2 and Faster R-CNN. In: 2020 IEEE International Conference on Big Data (Big Data). IEEE, pp 5592–5601
145. Soltani H, Amroune M, Bendib I, Haouam MY (2021) Breast Cancer Lesion Detection and Segmentation Based On Mask R-CNN. In: 2021 International Conference on Recent Advances in Mathematics and Informatics (ICRAMI). IEEE, pp 1–6
146. Jiangping Q, Zhang Y, Zhou H, et al (2021) Protein Crystal Instance Segmentation Based on Mask R-CNN. *Crystals (Basel)* 11:157. <https://doi.org/10.3390/cryst11020157>
147. Agarwal R, Díaz O, Yap MH, et al (2020) Deep learning for mass detection in Full Field Digital Mammograms. *Comput Biol Med* 121:103774. <https://doi.org/https://doi.org/10.1016/j.compbiomed.2020.103774>