

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الآلية والالكتروتقني
Département d'Automatique et d'Electrotechnique



Mémoire de Master

en Automatique

Spécialité : Automatique et Informatique industrielle

Présenté par

Seman Lydia Djoher

&

Raki Ibtissem

Détection de masses mammaires par apprentissage profond d'images échographiques pour l'aide à la décision

Dirigé par : Dr. Reguieg F. Zohra & Pr. Benblidia Nadjia

Année Universitaire 2020-2021

Remerciements

Au préalable, nous remercions Allah le tout puissant de nous avoir accordé la volonté et le courage de réaliser ce mémoire et de le terminer en temps et en heure.

Et c'est avec une reconnaissance incommensurable, que nous osons faire appel à toutes les âmes débordant de bonté, de générosité et de dévouement à notre égard.

Nous avons eu donc, le bonheur d'être si bien soutenues, aidées et entourées dans l'accomplissement de notre tâche.

Nos remerciements les plus sincères et notre profond respect sont adressés, tout d'abord, à Melle Reguieg F.Zohra, notre directrice de mémoire, pour sa grande patience, sa disponibilité, ses si précieuses directives et réconforts, qui nous ont tant aidé à traverser des moments ô combien compliqués, et ses conseils judicieux, qui ont éclairé nos réflexions. C'est donc là un immense honneur !

Nous tenons aussi à adresser nos plus profonds remerciements à Madame Benblidia Nadja, notre co-promotrice, pour ses encouragements et son soutien de si haute qualité.

Nos remerciements s'adressent également aux membres du jury qui nous ont fait l'honneur d'accepter de juger notre modeste travail.

Nous remercions aussi, nos familles, nos amis et nos collègues pour leur soutien moral, et leurs mots consolateurs qui nous ont donné le courage de continuer.

Enfin, nous remercions le corps professoral pour la qualité de l'enseignement qu'ils nous ont prodigué au cours de ces cinq années passées à l'université de Saad Dahleb Blida, ainsi que le corps administratif des départements d'électronique et d'automatique pour les efforts déployés assurant aux étudiants une formation actualisée et de haut niveau.

ملخص: في الوقت الحاضر، يمثل الكشف عن الأمراض في الموجات فوق الصوتية للثدي تحديًا حقيقيًا لمهنة الطب. لم تعد الأساليب التقليدية كافية. من الضروري الآن أن يكون لديك نظام للمساعدة في الكشف عن الأمراض باستخدام تقنيات التعلم العميق المختلفة، ومن ثم المساهمة الهائلة لتعلم النقل. هذا الأخير يساعد بشكل كبير في كسر حواجز البيانات المحدودة والقليلة والأداء الضعيف. يقدم النظام المعتمد عليه دراسة للنماذج المدربة مسبقًا وبأكثر دقة VGG16 و Inception-V3 و ResNet50. وقد تم تنقيح هاته النماذج وفقًا لاستراتيجيتي الضبط الجزئي والكلي.

في النتائج النهائية، كان VGG16 هو الأنسب بدقة 91.54% متجاوزا Inception-V3 و ResNet50

كلمات المفاتيح: الموجات فوق الصوتية للثدي؛ الشبكات العصبية التلافيفية؛ نظام مساعدة الكشف؛ نقل التعلم؛ VGG1

ResNet50؛ Inception V3

Résumé : De nos jours, la détection des pathologies dans les échographies mammaires représente un réel challenge pour le corps médical. Les approches classiques ne suffisent plus. Il est désormais essentiel, d'avoir un système d'aide à la détection des pathologies utilisant des différentes techniques du deep learning, suivant la contribution phénoménale de l'apprentissage par transfert. Ce dernier est d'une grande aide, permettant de briser les obstacles d'échantillons limités et des performances insatisfaisantes. Le système adopté présente une étude des modèles pré-entraînés plus exactement le VGG16, le ResNet50, et l'Inception V3. Ces trois modèles ont été affinés, suivant les stratégies du fine-tuning partiel et total. Dans la finalité des calculs, le VGG16 fut le plus approprié, avec une exactitude de 91,54% surpassant l'Inception-V3 et le ResNet.

Mots clés : Échographie mammaire, Réseaux de neurones convolutifs, Apprentissage par transfert, VGG16, Inception-V3, ResNet50, Système d'aide à la détection.

Abstract : Nowadays, the detection of pathologies in breast ultrasounds represent a real challenge for the medical staff. Traditional approaches are no longer sufficient; it is henceforth essential to have a pathology detection system using the various deep learning techniques, hence the phenomenal contribution of the transfer learning. The latter technique is of great help in removing the difficulties of limited samples and unsatisfactory performances. The adopted system, presents a study about the pre-trained model, VGG16, ResNet50 and Inception-V3, to be more specific. These three models have been refined using the fine-tuning strategies, total and partial. In the final calculations, the VGG16 was the most suitable model, with an accuracy of 91.54%, surpassing largely the Inception-V3 and the ResNet50.

Keywords : Breast ultrasound ; Deep convolutional neural network ; Computer Aided Diagnosis ; transfer learning ; VGG16 ; Inception-V3; ResNet50.

Table des matières

Introduction Générale.....	1
Chapitre 01: Contexte médical	4
1 Introduction.....	4
1.2 Anatomie du sein	5
1.2.1 Plan superficiel.....	5
1.2.2 Plan interne	6
1.2.3 Système lymphatique	7
1.3 Principales pathologies du sein.....	9
1.3.1 Pathologies bénignes du sein.....	9
1.3.2 Pathologies malignes du sein	10
1.4 Système d'acquisition.....	19
1.4.1 Imagerie par résonance magnétique mammaire	19
1.4.2 Mammographie	20
1.4.3 Echographie	22
1.5 Classification BI-RADS.....	26
1.6 Dépistage et Diagnostic médical.....	27
1.6.1 Dépistage.....	27
1.6.2 Diagnostic	28
1.6.3 Stratégie du diagnostic du cancer mammaire	29
1.7 Introduction aux systèmes d'aide au diagnostic.....	29
1.7.1 Qu'est-ce qu'un système d'aide (CAD) ?	29
1.7.2 Importance d'un système d'aide au diagnostic.....	30
1.8 Conclusion	30
Chapitre 02: Introduction à l'apprentissage automatique et profond	31
2.1 Introduction	31
2.2 Apprentissage automatique	32
2.2.1 Methodes d'apprentissage	33

2.2.2	La descente de gradient	35
2.2.3	Metrique d'évaluation	36
2.3	Apprentissage profond	38
2.3.1	Histoire du DL.....	40
2.3.2	Difference entre le Deep Learning et le Machine Learning	43
2.4	Réseaux de neurones artificiels.....	43
2.4.1	Principe de fonctionnement	45
2.4.2	Composantes principales du réseau de neurones.....	46
2.5	Architecture des RNs.....	50
2.5.1	Reseaux de neurones feed-forwarded	50
2.5.2	Perceptron simple	50
2.5.3	Reseaux de neurones multicouches MLP	51
2.5.4	Reseaux de neurones Récurrents.....	51
2.5.5	Reseaux de neurones à résonance	52
2.5.6	Reseaux de neurones auto-organisés.....	53
2.6	Reseaux de neurones convolutifs CNNs.....	54
2.6.1	Architecture des CNNs.....	54
2.6.2	Couches convolutive(CONV)	55
2.6.3	Couche de correction (Relu)	56
2.6.4	Couche de mise en commun (POOL)	56
2.6.5	Couche Fully Connected(FC)	57
2.6.6	Couche de perte (LOSS)	58
2.6.7	Choix d'hyperparametres	58
2.6.8	Avantages des CNNs	59
2.7	Apprentissage par transfert	60
2.8	Description de Quelques traveaux connexes réalisés en imagerie échographique.....	60
2.9	Conclusion	63
 Chapitre 03: Conception du système d'aide à la classification de lésions cancéreuses du sein et modèles des réseaux convolutifs		64

3.1 Introduction:.....	64
3.2 Conception d'un système d'aide à la detection et la classification des pathologies mammaires en échographie.....	64
3.2.1 Architecture du système	65
3.2.2 Analyse de la base de données	66
3.2.3 Prétraitement des images	68
3.2.4 Augmentation de données	Error! Bookmark not defined.
a Méthode courantes d'augmentation des données.	Error! Bookmark not defined.
3.3 Architectures des réseaux de neurones convolutifs	71
3.3.1 Modèle VGG	Error! Bookmark not defined.
3.3.2 Modèle Inception/GoogLeNet	76
3.3.3 Modèle ResNet50	87
3.4 Apprentissage par transfert.....	89
3.4.1 Stratégie 1 : extraction des caractéristiques.....	91
3.4.2 Ajustement de modèle pré-entraîné (fine-tuning).....	92
3.5 Conclusion	94
Chapitre 04: Mise en œuvre de 'BCNNV2' et résultats	95
4.1 Introduction:.....	95
4.2 Environnement de travail	95
4.2.1 Hardware	95
4.2.2 Software	96
4.3 Base de données	104
4.4 Préparation des données de l'application 'BCNNV2'	104
4.5 Architecture du système	107
4.6 Résultats.....	110
4.6.1 Modèle VGG16 avec un fine-tuning total	110
4.6.2 Modèle VGG16 avec un fine-tuning partiel.....	118
4.6.3 Modèle Inception-V3 avec un fine-tuning total	122
4.6.4 Modèle Inception-V3 avec un fine-tuning partiel	126
4.6.5 Modèle ResNet50 avec un fine-tuning total	130

4.6.6Modèle ResNet50 avec un fine-tuning partiel	134
4.7 Discussion et comparaison	137
4.8 Conclusion	140

Liste des figures

<i>Figure 1 .1</i> Sein et ses structures voisines	5
<i>Figure 1.2</i> schéma anatomique du sein (coupe sagittale)	7
<i>Figure 1.3</i> : ganglions lymphatique du sein.....	8
<i>Figure 1.4</i> : schéma des ganglions axillaires.....	8
<i>Figure 1.5</i> : carcinome canalaire infiltrant	Error! Bookmark not defined.
<i>Figure 1.6</i> :carcinome lobulaire infiltrant.....	Error! Bookmark not defined.
<i>Figure 1.7</i> : nombre de nouveaux cas atteints de cancer à l'échelle mondiale en 2020.	Error! Bookmark not defined.
<i>Figure 1.8</i> : nombre de morts des cancéreux à l'échelle mondiale en 2020	Error! Bookmark not defined.
<i>Figure 1.9</i> : symptômes du cancer du sein	Error! Bookmark not defined.
<i>Figure 1.10</i> : Adénocarcinome du sein	Error! Bookmark not defined.
<i>Figure 1.11</i> : cancer canalaire infiltrant et cancer canalaire in situ	Error! Bookmark not defined.
<i>Figure 1.12</i> : schéma d'installation d'une patiente	19
<i>Figure 1.13</i> : carcinomes intracanaux, prises de contrastes non-masses en IRM	Error! Bookmark not defined.
<i>Figure 1.14</i> : composants d'un mammographe.....	Error! Bookmark not defined.
<i>Figure 1.15</i> : images mammographiques : incidence de face droite (A) et gauche (B)	Error! Bookmark not defined.
<i>Figure 1.16</i> : zones normales du sein en échographie.....	Error! Bookmark not defined.
<i>Figure 1.17</i> : appareil d'échographie	Error! Bookmark not defined.
<i>Figure 1.18</i> : images échographiques des pathologies mammaires bénignes	25
<i>Figure 1.19</i> : cinétique du cancer	28
<i>Figure 1.20</i> Démarche stratégique du diagnostic du cancer du sein.....	29
<i>Figure 2.1</i> Modèles développés par ML.....	33
<i>Figure 2.2</i> : Concept schématique de la classification et la régression.	34
<i>Figure 2.3</i> :Etapes d'entraînement d'un modèle de la régression linéaire par DG	35
<i>Figure 2.4</i> :Matrice de confusion d'une classification binaire.....	36
<i>Figure 2.5</i> :Schéma de courbe ROC en orange et AUC en gris.	38
<i>Figure 2.6</i> intelligence artificielle, apprentissage automatique et apprentissage profond	Error! Bookmark not defined.

Figure 2.7: ML Vs DL	40
Figure 2.8: Neurone biologique.....	40
Figure 2.9: Exemple d'un réseau de neurones artificiels.	44
Figure 2.10: schéma d'un réseau de neurone artificiel	45
Figure 2.11: Couches d'un réseau de neurones	46
Figure 2.12: Fonction logistique (Sigmoïde).....	48
Figure 2.13: Fonction tangente hyperbolique.....	48
Figure 2.14: Fonction ReLu.....	49
Figure 2.15: Fonction Softmax.....	49
Figure 2.16: Perceptron simple	50
Figure 2.17: schéma du perceptron multicouche	51
Figure 2.18: réseaux de neurones récurrents	52
Figure 2.19: modèle ART	53
Figure 2.20: Carte auto-organisatrice de Kohonen	53
Figure 2.21: Réseau de neurones convolutifs	54
Figure 2.20: schéma d'une convolution avec un noyau de taille 3*3 et un pas de 2.....	55
Figure 2.23: Opération de pooling avec un noyau MaxPool de taille 2*2 et d'un pas de 2	57
Figure 2.24: Schéma d'une couche entièrement connectée avec 6 classes	57
Figure 2.25: Approche traditionnelle vs Approche de Transfert Learning.....	60
Figure 3.1 Schéma du système CAD désigné.....	65
Figure 3.2 Schéma désignant l'utilisation des datasets lors de la formation du modèle. ...	67
Figure 3.3: Effet miroir	68
Figure 3.4: Recadrage	69
Figure 3.5: Distorsions (décalages de couleurs)	70
Figure 3.6: Six configurations structurelles de VGG	73
Figure 3.7: Structure du modèle VGG16	74
Figure 3.8 Architecture du modèle VGG 16	75

Figure 3.9: Architecture de VGG 19	75
Figure 3.10: Couches détaillées du VGG 16 et VGG 19	76
Figure 3.11: Taux d'erreur dans l'ILSVRC 2014	77
Figure 3.12: Précision Top-1 par rapport au nombre d'opérations.....	77
Figure 3.13: Modèle Inception (version naïve)	78
Figure 3.14: Modèle Inception avec dimension réduite	78
Figure 3.15: Modèle Inception v2	80
Figure 3.16: Réseau Inception où chaque conv 5x5 est remplacée par deux conv 3x3	80
Figure 3.17: Normalisation par lots (BN).....	81
Figure 3.18: Mini-réseau remplaçant une convolution de 3x3	82
Figure 3.19: Inception après la factorisation des conv $n \times n$. Error! Bookmark not defined.	
Figure 3.20: Architecture de l'Inception-v3 (BN et Relu sont utilisés après Conv) Error! Bookmark not defined.	
Figure 3.21: Architecture générale de l'Inception-V4 (à gauche) Sur la droite : la composition détaillée de la tige	85
Figure 3.22: Résultats de la compétition de l'ILSVRC 2015	86
Figure 3.23: Bloc résiduel.....	88
Figure 3.24: Architecture du ResNet50.....	88
Figure 3.25: Techniques d'amélioration de l'apprentissage.	90
Figure 3.26: Performance de modèles du Deep Learning	91
Figure 3.27: Approche de Transfer Learning en Deep Learning	93
Figure 4.1: Anaconda Navigator	98
Figure 4.2 : Environnement Spyder	100
Figure 4.3 : Plateforme Tensorflow	101
Figure 4.4 : Bibliothèque Keras	102
Figure 4.5: Exemples d'images contenus dans le dataset BUSI	104
Figure 4.6: Augmentation des données	106
Figure 4.7: Exemple d'une convolution 3x3 avec un stride de 1	112
Figure 4.8: Exemple de maxpool 2*2 avec un stride de 2	113

Figure 4.9 : Exemple de l'opération Flatten	113
Figure 4.10 : Exemple de Dropout ou abandon.....	114
Figure 4.11 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des epoques.....	115
Figure 4.12 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des epoques	116
Figure 4.13 : Matrice de confusion pour VGG16	116
Figure 4.14 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	118
Figure 4.15 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	119
Figure 4.16 : Pourcentage d'exactitude et de perte de l'ensemble d'entraînement	119
Figure 4.17 : Matrice de confusion pour VGG16 avec un fine tuning partiel.....	120
Figure 4.18 : Modele Inception v3 avec un fine-tuning	123
Figure 4.19 : Evaluation de l'exactitude des ensembles d'entraînement et de validation du model inception v3 en fonction du nombre des époques.....	124
Figure 4.20 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation du model inception v3 en fonction du nombre des epoques	124
Figure 4.21 : Matrice de confusion pour Inception-V3	125
Figure 4.22 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	126
Figure 4.23 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	127
Figure 4.24 : Pourcentage d'exactitude et de perte de l'ensemble d'entraînement	127
Figure 4.25 : Matrice de confusion pour Inception-V3	127
Figure 4.26 : Modèle ResNetavec fine tuning	130
Figure 4.27 : Evaluation de l'exactitude des ensembles d'entraînement et de validation du modèle ResNet 50 en fonction du nombre des époques	131
Figure 4.28 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques	132
Figure 4.29 : Résultats obtenus avec la matrice de confusion	132

Figure 4.30: Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	134
Figure 4.31: Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel	134
Figure 4.32: Pourcentage d'exactitude et de perte de l'ensemble d'entraînement	135
Figure 4.33: Résultats obtenus avec la matrice de confusion	135
Figure 4.34: Résultats obtenus avec une répartition 80-10-10 et une répartition 90-5-5 du modèle VGG16 avec un fine-tuning partiel.....	137

Liste des tableaux

<i>Table 1.1:</i> Statistiques sur l'incidence et la mortalité du cancer du sein en 2020 dans le monde et par région	Error! Bookmark not defined.
<i>Table 1.2 :</i> Classification par stade de l'UICC.....	18
<i>Table 1.3 :</i> Catégories d'évaluation BIRADS. Mammographique de l'ACR.....	26
<i>Table 1.4 :</i> Catégories d'évaluation BIRADS. Echographique de l'ACR.....	27
<i>Table 2.1:</i> Evolutions historiques du deep learning.....	Error! Bookmark not defined. 2
<i>Table 2.2 :</i> Différence entre le deep et le machine learning .	Error! Bookmark not defined.
<i>Table 2.3 :</i> Différences entre les Cnns et les Rnns	65
<i>Table 3.1:</i> Résultat obtenu sur ImagNet.....	71
<i>Table 3.2 :</i> GoogleNet l'incarnation de l'architecture Inception.....	79
<i>Table 3.3 :</i> Comparaison entre Inception V1, Inception v2 et Inception v3	86
<i>Table 3.4 :</i> Différents paramètres de l'apprentissage par transfert	90
<i>Table 4.1 :</i> Répartition de l'ensemble de données en classes. (bénignes, malignes, normales)	104
<i>Table 4.2 :</i> Répartition 80-10-10 de l'ensemble de données en classes (train, val, test) ...	105
<i>Table 4.3:</i> Répartition 90-5-5 de l'ensemble de données en classes.(train, val, test)	105
<i>Table 4.4:</i> Paramètres des couches ajoutées au modèle VGG16 avec un fine-tuning partiel	107
<i>Table 4.5:</i> Paramètres des couches ajoutées au modèle Inception v3 avec un fine-tuning partiel.....	108
<i>Table 4.6:</i> Paramètres des couches ajoutées au modèle Resnet 50 avec un fine-tuning partiel.....	108
<i>Table 4.7:</i> Paramètres des couches ajoutées au modèle VGG16 avec un fine-tuning total...	109
<i>Table 4.8:</i> Paramètres des couches ajoutées au modèle Inception v3 avec un fine-tuning total.....	109
<i>Table 4.9:</i> Paramètres des couches ajoutées au modèle Resnet 50 avec un fine-tuning total.....	110
<i>Table 4.10:</i> Grandes lignes de l'architecture proposée.....	111
<i>Table 4.11:</i> Erreur d'exécution de chaque algorithme après 70 itérations.....	115
<i>Table 4.12:</i> Résultats obtenus avec la matrice de confusion	117

<i>Table 4.13:</i> Rapport de classification obtenu avec la matrice de confusion	121
<i>Table 4.14:</i> Matrice de confusion avec 3 classes	121
<i>Table 4.15:</i> Spécificité et sensibilité du modèle VGG16.....	122
<i>Table 4.16:</i> Erreur d'exécution de chaque algorithme après 70 époques	124
<i>Table 4.17:</i> résultats obtenus avec la matrice de confusion	126
<i>Table 4.18:</i> résultats obtenus avec la matrice de confusion	129
<i>Table 4.19:</i> Spécificité et sensibilité du modèle Inception v3.....	129
<i>Table 4.20:</i> Erreur d'exécution de chaque algorithme après 70 époques.....	131
<i>Table 4.21:</i> Résultats obtenus avec la matrice de confusion.....	133
<i>Table 4.22:</i> résultats obtenus avec la matrice de confusion	136
<i>Table 4.23:</i> Spécificité et sensibilité du modèle ResNet 50.....	136
<i>Table 4.24:</i> Comparaison entre les différents modèles développés.....	139
<i>Table 4.25:</i> Résultats finaux du système 'BCNN' sur l'ensemble test	140

Listes des acronymes et abréviations

CCIS : carcinome canalaire in situ

CCI : carcinome canalaire infiltrant

CLIS : carcinome lobulaire in situ

CLI : carcinome lobulaire infiltrant

EGF : facteur de croissance épidermique

IRM : Imagerie par résonance magnétique

RX : rayons X

IA : intelligence artificielle

ML : machine learning

DG : Descente de gradient

DL : deep learning

AP : apprentissage profond

CNN : réseaux de neurones convolutifs (convolutional neuronal Network)

RNP : réseaux de neurones profonds

MLP : perceptron multicouche

FC : Fully Connected Layer

CAD : système d'aide à la prise de décision

VGG : Visual Geometry Group

BN : Batch normalization

DenseNet: Densely Connected Convolutional Network

Spyder : Scientific PYTHON Development EnviRonment

Numpy : Numerical Python

BUSI Dataset: Breast Ultrasound Images Dataset

Introduction générale

Prenant naissance de la transformation des cellules normales en cellules tumorales, le cancer représente, depuis ces dernières années, l'une des principales causes de mortalité dans le monde, avec près de 1.80 millions de cas en 2020 [1].

Le cancer du sein se classe donc, au premier rang parmi les cancers les plus diagnostiqués. Le risque d'atteinte, devient encore plus effrayant en Algérie, avec 12536 cas en 2020, il occupe donc, la première place, suivant son incidence et son taux de mortalité [2]. Malheureusement, ce lourd fardeau aussi bien mondial que national, menace la population future avec une effroyable augmentation de personnes touchées. Ceci est, en grande partie, dû à son diagnostic tardif, qui résulte en un traitement lourd, coûteux avec une chance de guérison minime.

Dans le but de réduire la croissance de mortalité et de personnes affectées, obtenir un traitement plus susceptible d'être efficace, avec plus de chance de survie ainsi que la réduction des coûts, la détection précoce est nécessaire motivant, de ce fait, les campagnes de « lutte contre le cancer du sein », à mettre un accent, sur la promotion de la santé et le diagnostic en temps opportun.

Il existe de nombreuses stratégies de dépistage, afin de diagnostiquer le cancer du sein. Etant l'une d'elles, l'échographie mammaire, est connue pour être un examen qui permet de visualiser et observer l'organe atteint, en employant des ultrasons. Elle peut préciser la nature d'une lésion, solide ou liquide, dépistée à la mammographie.

Les principaux avantages de cette technique, est qu'elle soit indolore et peu coûteuse.

Néanmoins, l'interprétation des clichés avec précision, en peu de temps par le radiologue est assez limitée, la disponibilité d'un système d'aide à la détection par ordinateur (CAD), se voit primordial pour une détection en un temps record, avec une précision importante, rendant ainsi plus facile, la tâche du médecin traitant de prescrire la médication adéquate, avant la propagation du cancer.

Notre travail porte sur la mise en œuvre, d'un système d'aide à la détection, qui analysera, des images échographiques mammaires, usant des techniques d'apprentissage profond, pour ensuite les catégoriser en trois classes (bénignes, malignes et normales). Dans ce cadre, les réseaux de neurones à convolution, permettent l'extraction automatique des informations pertinentes des images, contrairement à l'apprentissage automatique, qui utilise des méthodes plus traditionnelles, réduisant ainsi, le taux d'erreur des fausses détections.

Nous étudierons, à cet effet, les différentes architectures des réseaux de neurones convolutifs telles que le VGG16, le ResNet50, et l'Inception-V3 avec un affinement des paramètres d'apprentissage, afin de trouver le modèle le plus performant, pour réussir cette analyse.

Afin de mener à bien ce travail de recherche, le mémoire a été structuré en quatre chapitres :

- **Le premier chapitre** traite le contexte médical. Nous débuterons par une description générale de l'anatomie de l'organe touché, soit le sein, les différentes pathologies mammaires, ainsi qu'une présentation des différents systèmes d'acquisition en imagerie médicale.
- **Le deuxième chapitre** parcourt des notions sur l'apprentissage automatique, l'apprentissage profond, en insistant sur les réseaux neuronaux convolutifs.

- **Le troisième chapitre** présente la conception de notre système de classification des pathologies mammaires, grâce à une approche basée sur les réseaux de neurones à convolution, ainsi que les différents modèles pré-entraînés utilisés.

- **Le quatrième chapitre** est consacré à l'étude expérimentale effectuée sur l'ensemble de données échographiques du sein, suivie par les résultats obtenus.
- Enfin, nous clôturerons ce mémoire par une conclusion générale.

1.1 Introduction

Etant à la fois, l'une des formes de cancer les plus fréquentes et les plus meurtrières chez la femme, le cancer du sein se situe au 1^{er} rang des cancers incidents chez la femme, dépassant nettement le cancer du poumon et le cancer colorectal.

Selon l'OMS, en 2020, le taux s'élève à 2,26 millions malades atteints du cancer du sein soit environ 11,7% de nouveaux cas, dont 12 536 personnes en Algérie. Le nombre de mortalité est estimé au nombre de 1,80 million de décès dans le monde, donc un pourcentage atteignant presque les 6.9% (4 116 décès en Algérie) [1,2,3]. Un nombre assez monstrueux jugeant le dénombrement total de la population algérienne.

A cet égard, il est primordial pour les individus ayant discerné les symptômes de passer un examen de dépistage dans les plus brefs délais, car la détection précoce du cancer augmente considérablement le taux de guérison du malade et dans certains, elle permet un traitement moins intrusif.

Habituellement, c'est le radiologue qui a pour mission d'effectuer l'examen, avant d'analyser et interpréter les résultats des images obtenues. Cependant, la complexité du cancer, dans certains cas, amène à l'importance de recourir aux systèmes d'aide au diagnostic afin d'assister les radiologues pendant l'opération, permettant ainsi d'avoir de meilleurs résultats.

Dans ce chapitre, nous commencerons par dévoiler l'anatomie du sein, suivi de près par les différentes pathologies mammaires, leurs grades, les systèmes d'acquisition, ainsi que le diagnostic médical. Enfin, nous clôturerons ce chapitre, avec une présentation d'un système d'aide au diagnostic.

1.2 Anatomie du sein

Situés au niveau du thorax, les seins¹ (figure 1.1) sont présents chez les hommes comme les femmes, mais ne sont totalement fonctionnels que chez la femme. Leur fonction biologique est de produire du lait pour les nouveau-nés.

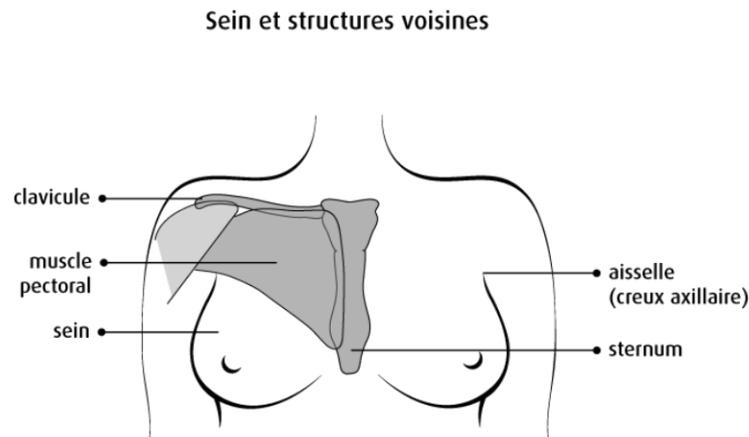


Figure 1.1 : Sein et ses structures voisines [4]

1.2.1 Plan superficiel

Le sein est recouvert d'une enveloppe cutanée, qui s'étend jusqu'à la région du mamelon. Ce dernier est entouré d'une zone pigmentée, appelée l'aréole.

- **Le mamelon** : situé au centre de l'aréole, c'est la partie la plus pigmentée du sein. Il est constitué de fibres musculaires, pouvant se contracter lui permettant ainsi de durcir ou de pointer vers l'extérieur. Etant une zone sensible, il possède une peau extrêmement fine, facilitant la traversée du lait maternel lors de l'allaitement.
- **L'aréole** : représentant la surface ronde rosée ou brunâtre, qui entoure le mamelon, sa taille est variable d'un individu à un autre. En général, son diamètre est de 3cm. Elle contient de petites glandes appelées « glandes aréolaires ». Ces dernières peuvent sécréter une substance huileuse qui permet la protection de l'organe contre les infections et le dessèchement [4].

¹ Sein : du latin « *sinus* ». La partie du corps humain qui porte les mamelles, qui forme l'extérieur de la poitrine, et qui, étant bombée, a mérité d'être appelée sein.

1.2.2 Plan interne

Sur le plan intérieur, le sein se compose de tissu adipeux, conjonctif, de glandes, de canaux et un système lymphatique (figure 1.2).

- **Tissu adipeux** : est un ensemble de cellules serrées les unes aux autres, qui stockent des graisses. Nous pouvons en distinguer deux sortes de tissu adipeux ; le blanc, qui prend en charge la réserve énergétique de l'organisme et le brun, qui est une source de chaleur pour le corps. Son rôle principal est d'isoler et protéger l'organe [5].
- **Tissu conjonctif** : c'est un tissu lâche, riche en fibres conjonctives et élastiques, où les vaisseaux et les nerfs circulent. Il entoure toutes les structures fonctionnelles de l'organe [6].
- **Lobules** : représentant des groupes de glandes, leur nombre est situé entre 15 et 25 lobules pour chaque sein. Leur principale fonction est de produire du lait maternel, lors d'une grossesse.
- **Ligaments** : composés de bandes serrées de tissu conjonctif pour soutenir les seins, ils fixent les seins aux muscles du thorax en traversant de la peau jusqu'à atteindre les muscles.
- **Canaux lactifères** : ce sont des tubes véhiculant le lait des lobules jusqu'au mamelon [7].

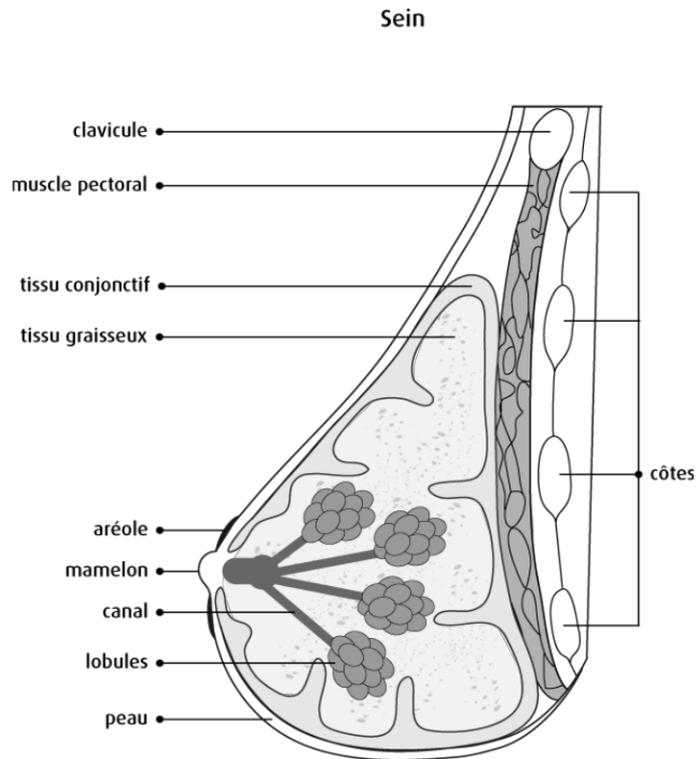


Figure 1.2 : Schéma anatomique du sein (coupe sagittale) [4]

1.2.3 Système lymphatique

Le sein est parcouru par de nombreux vaisseaux sanguins et lymphatiques (figure 1.3).

Le réseau de vaisseaux lymphatiques a pour obligation de transporter la lymphe des tissus des seins, jusqu'à de petites masses de tissu lymphatique en forme de haricot appelées ganglions lymphatiques, entourant la zone mammaire. Le système lymphatique joue un rôle dans le système immunitaire et le processus cicatriciel (aide à combattre les infections).

De manière à évacuer la lymphe hors du sein, nous pouvons différencier plusieurs groupes de ganglions :

- **Les ganglions sus-claviculaire** : se situent au-dessus de la clavicule.
- **Les ganglions infra-claviculaire ou sous-claviculaire** : se trouvent sous la clavicule.
- **Les ganglions mammaires internes** : situés à l'intérieur du thorax, autour du sternum.

Ganglions lymphatiques du sein

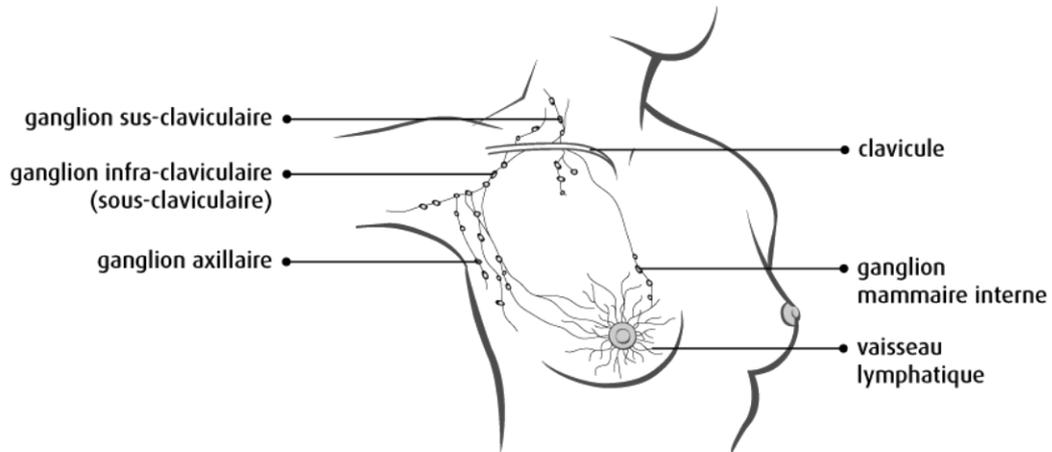


Figure 1.3 : Ganglions lymphatiques du sein [4]

- **Les ganglions axillaires** : se trouvant à l'aisselle (creux axillaire), leur nombre va de 30 à 50 par aisselle [4, 7]. Ils sont répartis en 3 niveaux, suivant leur proximité au large muscle grand pectoral (figure 1.4).

Ganglions axillaires

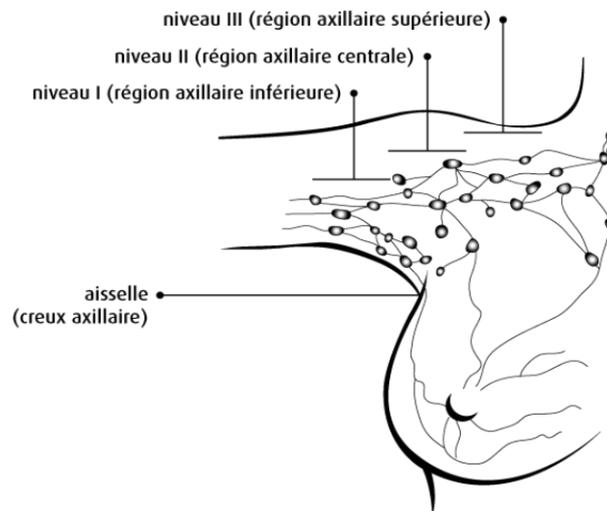


Figure 1.4 : Schéma des ganglions axillaires [4]

1.3 Principales pathologies du sein

Etant un organe qui possède un arbre galactophorique², le sein peut être touché par un nombre assez important de maladies. Ces dernières sont soit de nature non cancéreuse (bénigne), ou cancéreuse (maligne).

1.3.1 Pathologies bénignes du sein

Très fréquentes parmi les lésions du sein, les pathologies bénignes sont des tumeurs peu menaçantes, faciles à repérer et immobiles. Elles ne se propagent pas à d'autres parties du corps, n'entraînent donc pas de métastases.

Il existe plusieurs types de lésions bénignes, on en compte parmi elles :

- **Fibroadénome** : le fibroadénome ou l'adénofibrome est une tumeur bénigne, hormonosensible, à double composante épithéliale et conjonctive, qui se développe à partir de canaux intralobulaires et des acini. Bien souvent, la tuméfaction est indolore, palpable (nodule arrondi ou ovalaire), lente à se développer et mesure de 30 mm à 5 cm (pour les fibroadénomes géants). Il peut être multiple (15% des femmes) ou bilatéral (10% des femmes). Malgré sa possible existence dans toutes les tranches d'âge, il touche généralement, les jeunes femmes (< 40 ans) [8, 9].
- **Tumeur phyllode** : aussi appelée cystosarcome phyllode, la tumeur phyllode est beaucoup moins fréquente que le fibroadénome (seulement 2% des tumeurs mammaires). Sa forme arrondie peut rappeler l'adénofibrome. Cependant, la différence réside dans sa masse (plus ferme) et sa taille (très variable). C'est une tumeur mixte, à la fois mésenchymateuse³ et épithéliale. Elle peut apparaître le plus souvent, après 40 ans. Selon son analyse histologique ou son grade, la tumeur phyllode peut être soit bénigne, récidivante, maligne ou métastatique. Il est donc essentiel pour le médecin, d'intervenir chirurgicalement afin d'éviter que la lésion ne récidive [8,9].

² Se dit des canaux excréteurs des glandes mammaires.

³ Relative au mésenchyme, tissu embryonnaire pouvant se transformer en tissu conjonctif cartilagineux, osseux, musculaire, etc.

- **Papillome intracanalair** : il s'agit d'une tumeur bénigne semblable à une verrue, qui se forme dans les canaux galactophoriques. Cette pathologie représente 10% des tumeurs bénignes. Les hommes comme les femmes, peuvent avoir un papillome intracanalair. Il est, néanmoins, plus présent chez la femme. Habituellement, il n'augmente pas le risque du cancer du sein. Toutefois, si une quelconque croissance cellulaire anormale est observée (des lésions d'hyperplasie canalaire atypique), la menace augmente considérablement, surtout en présence de plusieurs papillomes intracanaux. Le traitement est chirurgical [8,9,10].
- **Kystes** : ce sont des nodules remplis de liquide ou de semi-liquide, produit par les glandes mammaires. Ronds ou ovales, ils sont liés à la dilatation d'un canal ou d'un lobule. Ils peuvent être palpables et simples ou complexes. Très douloureux sous tension, les kystes sont bénins et donc non-cancéreux. C'est la forme la plus présente chez les femmes (un tiers des femmes de 30 à 50 ans). L'échographie est le meilleur examen pour repérer le diagnostic. En général, il ne nécessite pas de traitement, car il disparaît seul. En cas de gêne, il peut être soigné soit sous échographie pour l'altérer en utilisant une seringue, ou de le retirer définitivement en passant par la chirurgie [8,9,10].
- **Cytostéatonécrose** : cytotéatonécrose ou adiponécrose, est un phénomène lié à la nécrose du tissu adipeux mammaire, qui apparaît souvent après un traumatisme mammaire. Suite à sa petite masse mal limitée, ferme, arrondie superficielle et adhérente à la peau, elle mime parfaitement un cancer. Elle atteint le plus souvent, les femmes ménopausées. Le diagnostic repose sur des critères cliniques, radiologiques et parfois histologiques [8,9,10].

Il existe évidemment d'autres tumeurs bénignes, telles que les maladies fibrokystiques, les mastites inflammatoires et d'autres plus rares comme les lipomes, les hamartomes, les hyperplasies épithéliales, les adénomes, les neurofibromes, etc.

1.3.2 Pathologies malignes du sein

Les tumeurs malignes du sein naissent de la prolifération d'une cellule issue d'un composant normal du sein, devenue maligne. Elle est généralement originaire, d'un canal ou d'un lobule.

Contrairement aux tumeurs bénignes, les tumeurs malignes se présentent sous forme de contours délimités. Dans certains cas, ces tumeurs sont bien limitées ce qui retarde fréquemment le diagnostic du cancer, rappelant de ce fait, les tumeurs bénignes.

Les tumeurs malignes se constituent de cellules cancéreuses dévoilant plusieurs anomalies, par rapport aux cellules normales (forme, taille, contours). Ce sont des cellules ayant perdues leurs caractéristiques originelles [11].

Lorsque les tumeurs malignes sont citées, la première chose qui nous vient à l'esprit est, sans aucun doute, le cancer du sein.

a Définition

Le cancer du sein représente une maladie cellulaire, qui se développe au niveau du sein, autrement dit, c'est une tumeur maligne qui atteint les glandes mammaires. Il résulte de la transformation cancéreuse des cellules glandulaires du sein, qu'elles soient des cellules des canaux galactophores (carcinome canalaire du sein) ou des cellules des lobules (carcinome lobulaire du sein).

Les carcinomes canalaire (figure 1.5) et lobulaire (figure 1.6), peuvent être in situ (le cancer reste dans son emplacement d'origine), ou invasifs (le cancer envahit les tissus voisins) [12].

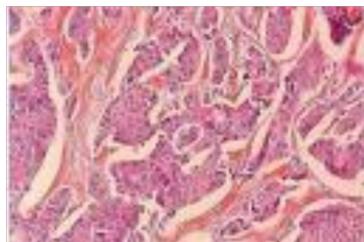


Figure 1.5 : Carcinome canalaire infiltrant [13]

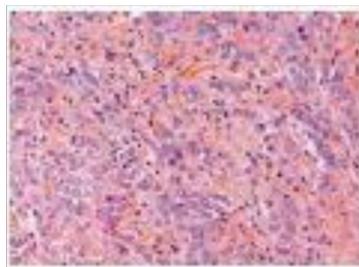


Figure 1.6 : Carcinome lobulaire infiltrant [13]

Une accumulation d’erreurs dans le code génétique de la muqueuse du sein, conduit à la cancérisation d’une cellule normale. Ce code est transmis à la cellule fille, conduisant, au moment de la division cellulaire, à une multiplication anarchique, non-contrôlée et illimitée de la cellule cancéreuse. Cette dernière envahit, sans plus attendre, les tissus voisins, les vaisseaux sanguins et les vaisseaux lymphatiques. Ceci conduira donc, à l’apparition d’une tumeur, risquant le développement de métastases ganglionnaires (à travers les vaisseaux lymphatiques) et le développement de métastases à distance, dans les autres organes (à travers les vaisseaux sanguins).

Plusieurs facteurs de risque pour le cancer du sein sont identifiées ; soit par l’âge (vieillesse des cellules), une ménopause tardive, une grossesse tardive, l’âge précoce des premières règles, ou par le facteur génétique qui représente également, une source de risque (5% à 10% des cancers du sein) [14]. Malheureusement en 2020, le nombre de femmes atteintes s’élève à 2.3 millions (figure 1.7) avec 685 000 décès dans le monde (figure 1.8).

Au cours de ces 5 dernières années, 7.8 millions de femmes se sont fait diagnostiquer un cancer du sein (tableau 1.1), ce qui lui permet d’occuper la première place du classement des cancers à l’échelle mondiale [15].

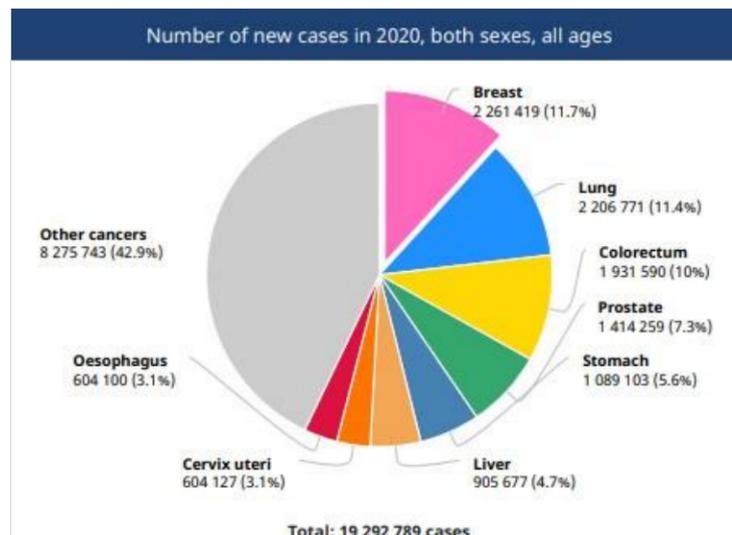


Figure 1.7 : Nombre de nouveaux cas atteints de cancer à l’échelle mondiale en 2020 [16]

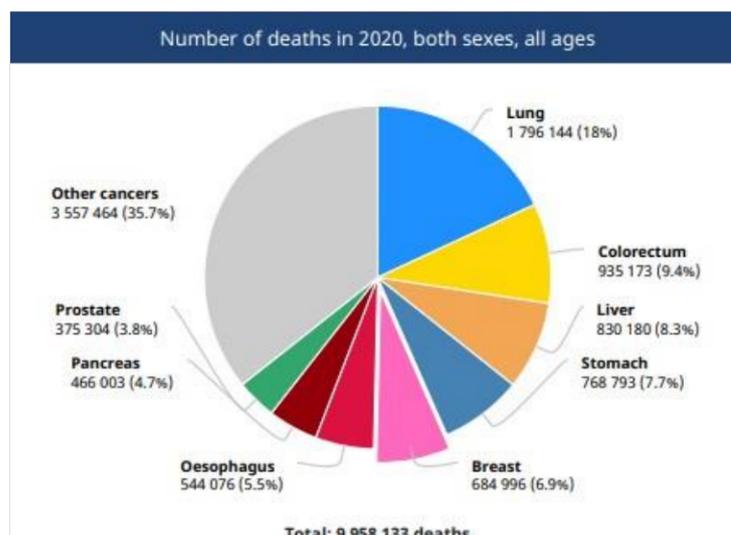


Figure 1.8 : Nombre de décès de cancéreux à l'échelle mondiale en 2020 [16]

Cancer incidence and mortality statistics worldwide and by region												
	Incidence						Mortality					
	Both sexes		Males		Females		Both sexes		Males		Females	
	New cases	Cum. risk 0-74 (%)	New cases	Cum. risk 0-74 (%)	New cases	Cum. risk 0-74 (%)	Deaths	Cum. risk 0-74 (%)	Deaths	Cum. risk 0-74 (%)	Deaths	Cum. risk 0-74 (%)
Eastern Africa	45 709	3.57	-	-	45 709	3.57	24 047	1.99	-	-	24 047	1.99
Middle Africa	17 896	3.40	-	-	17 896	3.40	9 500	1.93	-	-	9 500	1.93
Northern Africa	57 128	5.12	-	-	57 128	5.12	21 524	1.89	-	-	21 524	1.89
Southern Africa	16 526	5.37	-	-	16 526	5.37	5 090	1.70	-	-	5 090	1.70
Western Africa	49 339	4.49	-	-	49 339	4.49	25 626	2.47	-	-	25 626	2.47
Caribbean	14 712	5.48	-	-	14 712	5.48	5 874	2.00	-	-	5 874	2.00
Central America	38 916	4.23	-	-	38 916	4.23	10 429	1.16	-	-	10 429	1.16
South America	156 472	6.14	-	-	156 472	6.14	41 681	1.50	-	-	41 681	1.50
Northern America	281 591	9.71	-	-	281 591	9.71	48 407	1.36	-	-	48 407	1.36
Eastern Asia	551 636	4.60	-	-	551 636	4.60	141 421	1.13	-	-	141 421	1.13
South-Eastern Asia	158 939	4.46	-	-	158 939	4.46	58 670	1.65	-	-	58 670	1.65
South-Central Asia	254 881	2.88	-	-	254 881	2.88	124 975	1.50	-	-	124 975	1.50
Western Asia	60 715	5.00	-	-	60 715	5.00	20 943	1.73	-	-	20 943	1.73
Central and Eastern Europe	158 708	6.28	-	-	158 708	6.28	51 488	1.75	-	-	51 488	1.75
Western Europe	169 016	9.69	-	-	169 016	9.69	43 706	1.65	-	-	43 706	1.65
Southern Europe	120 185	8.45	-	-	120 185	8.45	28 607	1.44	-	-	28 607	1.44
Northern Europe	83 177	9.35	-	-	83 177	9.35	17 964	1.45	-	-	17 964	1.45
Australia and New Zealand	23 277	10.41	-	-	23 277	10.41	3 792	1.28	-	-	3 792	1.28
Melanesia	2 215	5.37	-	-	2 215	5.37	1 121	2.90	-	-	1 121	2.90
Polynesia	261	7.42	-	-	261	7.42	83	2.44	-	-	83	2.44
Micronesia	120	4.20	-	-	120	4.20	48	1.59	-	-	48	1.59
Low HDI	109 572	3.88	-	-	109 572	3.88	58 586	2.21	-	-	58 586	2.21
Medium HDI	307 658	3.04	-	-	307 658	3.04	147 427	1.52	-	-	147 427	1.52
High HDI	825 438	4.57	-	-	825 438	4.57	247 486	1.36	-	-	247 486	1.36
Very high HDI	1 017 459	8.17	-	-	1 017 459	8.17	231 093	1.46	-	-	231 093	1.46
World	2 261 419	5.20	-	-	2 261 419	5.20	684 996	1.49	-	-	684 996	1.49

Tableau 1.1 : Statistiques sur l'incidence et la mortalité du cancer du sein en 2020 dans le monde et par région [16]

***b* Symptômes du cancer du sein**

Lors des premiers stades de la maladie, le cancer ne montre, parfois, aucun symptôme. Les signes apparaissent généralement, lorsque la tumeur est suffisamment grosse pour la sentir au toucher, ou lorsqu'elle s'est propagée aux tissus et organes voisins (figure 1.9).

En général, le cancer du sein se manifeste par :

- Une masse ou un épaissement du sein, c'est le signe le plus courant qui est observé. La boule n'est ordinairement pas douloureuse, elle est dure et se présente dans des contours irréguliers.
- Des ganglions durs au niveau du creux axillaire (aisselle).
- Des changements de la peau du sein (rougeurs, rétraction, peau orangée), de la taille ou de la forme (un œdème, une chaleur importante).
- Des modifications du mamelon ou de l'aréole (rétraction, changement de coloration, écoulement anormal).

Si par malheur, le cancer n'est pas diagnostiqué, malgré l'apparition claire des premiers signaux, d'autres symptômes appelés tardifs se manifesteront, tels que :

- Des douleurs osseuses, des nausées, une perte de poids et d'appétit, une jaunisse, un essoufflement, une accumulation de liquide autour des poumons, une vision trouble, un affaiblissement musculaire, etc [17].



Figure 1.9 : Symptômes du cancer du sein [18]

c Types de cancer du sein

Après avoir passé des années à étudier plus de 2000 différents cancer du sein, la collaboration entre l'équipe de recherche canadienne et celle du Royaume-Uni, ont reporté avoir identifié 10 différents types de cette pathologie, chacune d'elles, associée à un pronostic très distinct. L'identification selon le niveau d'avancement de la tumeur et son agressivité, sont les deux catégories de pronostics existantes. Huit sur dix de ces cancers, sont des cancers canaux [19].

Les cancers fréquemment repérés, sont les adénocarcinomes (figure 1.10), ou les cancers glandulaires (95%) qui se développent à partir des cellules canaux et des lobules.

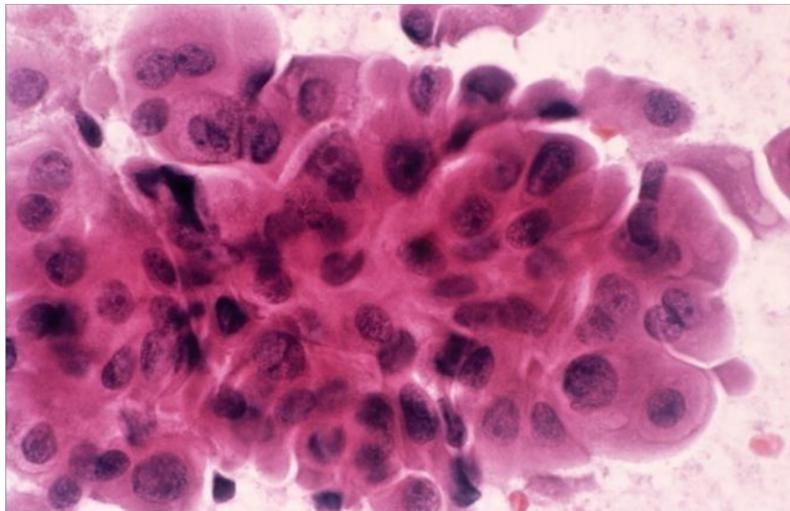


Figure 1.10 : Adénocarcinome du sein [19]

➤ Situations anatomopathologiques

Il existe deux situations anatomopathologiques distinctes pour tous les types de cancers :

- Si les cellules cancéreuses se trouvent uniquement à l'intérieur des canaux ou des lobules, il s'agit du cancer in situ.

- Si les cellules cancéreuses infiltrent le tissu entourant les canaux et les lobules, il s'agit alors du cancer infiltrant.

- *Carcinome canalaire in situ (CCIS)* : c'est une forme précoce du cancer du sein, se développant à l'intérieur des canaux de lactation du sein. Les cellules cancéreuses ne s'étant pas encore répandues dans les tissus voisins, décroissent les risques de migration du cancer, vers les ganglions lymphatiques et les autres organes.

- *Carcinome lobulaire in situ (CLIS)* : dans cette forme, les cellules cancéreuses s'accumulent à l'intérieur des lobules du sein. Il n'est certes, pas un cancer à proprement parler. Cependant, il présente un risque qu'il se développe en un cancer du sein invasif.
- *Carcinome canalaire infiltrant (CCI)* : ce type de cancer est le plus fréquent (de 70-80% des cancers diagnostiqués). Il se manifeste dans les canaux mammaires, traverse leurs parois et se propage au tissu mammaire voisin. Les risques de propagation vers les ganglions lymphatiques et les autres organes, sont donc plus élevés.
- *Carcinome lobulaire infiltrant (CLI)* : 10 à 15% des cancers diagnostiqués sont des CLI. Essentiellement observé chez les femmes de tranche d'âge entre 45 et 55 ans, ce cancer naît dans les lobules du sein, traverse les glandes et se répand au tissu mammaire voisin. De ce fait, il se répand également jusqu'aux ganglions lymphatiques et les autres parties du corps [12].

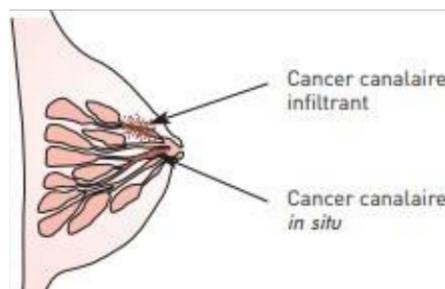


Figure 1.11 : Cancer canalaire infiltrant et cancer canalaire in situ [12]

➤ Caractérisation de la tumeur

La prolifération des cellules cancéreuses est sous l'influence de récepteurs spécifiques, connus sous le nom des hormones et de l'EGF. Ces récepteurs doivent être identifiés afin de détecter le mode de prolifération des tumeurs. Nous distinguons donc :

- Les cancers de type luminal A ou B : ils se développent à partir des cellules épithéliales de la lumière des canaux ou des lobules. Ils possèdent des récepteurs œstrogènes et à la progestérone (hormones).
- Les cancers de type HER2+ : les cellules cancéreuses présentent à leur surface des récepteurs HER2+.

- Le cancer triple négatif : il est formé de cellules qui n'ont aucun des récepteurs cités précédemment. Il est donc considéré comme un cancer distinct avec ses propres options de traitement. Ce type cancer est habituellement de type basal, puisqu'il présente des protéines modifiées inhabituelles pour lui. La plupart de ces cancers sont des CCI, leurs tumeurs sont agressives ou de haut grade.

- **Cancer inflammatoire**

Cette forme de cancer apparait lorsque les cellules cancéreuses bloquent les vaisseaux lymphatiques de la peau du sein. Sa nomination « inflammatoire » vient du fait que le sein devient rouge et enflé. Il atteint principalement les jeunes femmes et les femmes d'origine africaine. Cette apparence est certes rare mais agressive, la tumeur se développe et se propage rapidement. Majoritairement, le cancer inflammatoire s'est déjà propagé dans les ganglions lymphatiques et les autres organes lors du diagnostic.

- **Maladie de Paget du sein**

C'est un type de rare de cancer du sein (seulement 1-3% des tumeurs mammaires). Il naît dans les canaux lactifères et se manifeste en premier lieu sur la peau du mamelon, la maladie affecte généralement un seul sein [20].

- **Cancer métastatique**

Dans cette forme, le cancer est de stade 4, ou métastatique. Les cellules cancéreuses envahissent les autres parties du corps. La propagation se fait généralement aux ganglions lymphatiques voisins situés autour de la clavicule, du sternum et dans l'aisselle. Les métastases peuvent également se montrer dans des organes plus éloignés (muscles du thorax, os, foie, poumon, cerveau etc.) [21].

d Classification du cancer du sein

Afin de choisir le traitement le plus adéquat, il est essentiel de déterminer le stade du cancer du sein chez le malade. La stadification, qui nous permet d'évaluer l'avancement du cancer, est effectuée à partir d'examen cliniques, radiologiques et anatomopathologiques.

La taille et l'infiltration de la tumeur, l'atteinte ou non des ganglions lymphatiques et la présence ou non des métastases, sont les trois critères permettant l'identification du stade du cancer selon la classification TNM.

Le système de classification TNM est établi par l'Union internationale contre le cancer (UICC) et de l'American Joint Committee on Cancer (AJCC). Les lettres T N M représentent :

- ❖ Le T pour *Tumeur* correspond à la taille et l'infiltration de la tumeur primitive : de T_0 pour une tumeur non-palpable à T_4 pour une tumeur avec extension à la paroi/peau et une tumeur inflammatoire.
- ❖ Le N pour *Node* (ganglion en anglais) correspond au degré d'envahissement des ganglions lymphatiques, de N_x à N_3 .
- ❖ Le M pour *Metastase* pour la présence ou l'absence des métastases à distance, de M_0 pour l'absence de métastases à M_1 et pour la présence de métastases à distance.

La combinaison des lettres TNM représente les stades du cancer (tableau 1.1). Ces derniers sont exprimés par des chiffres romains allant de I (0) à IV [22].

Stade	T-N-M
0	Tis N0 M0
I	T1 N0 M0
IIA	T0 N1 M0 ; T1 N1 M0 ; T2 N0 M0 ;
IIB	T2 N1 M0 ; T3 N0 M0
IIIA	T0 N2 M0 ; T1N2 M0 ; T2N2 M0 ; T3 N1 M0 ; T3 N2 M0
IIIB	T4 N0 M0 ; T4 N1 M0 ; T4 N2 M0
IIIC	Tous T N3 M0
IV	Tous T Tous N M1

Tableau 1.2 : Classification par stade de l'UICC [22]

Le système de classification TNM distingue le stade clinique pré-thérapeutique, qu'on appelle la classification « cTNM » (c'est un examen clinique réalisé avant tout traitement, pour définir le stade pré-thérapeutique du cancer.) et le stade anatomopathologique post-chirurgical nommé classification « pTNM » (c'est un examen anatomopathologique des tumeurs et une analyse des ganglions prélevés qui permet l'identification du stade anatomopathologique du cancer).

1.4 Systèmes d'acquisition

Grâce aux grandes découvertes lors du 20^e siècle, l'imagerie médicale est née. En à peine une centaine d'année, ses nombreuses techniques et très souvent complémentaires, continuent encore d'évoluer suivant les progrès de la médecine, de la physique, des mathématiques appliqués et de l'informatique.

C'est une pratique regroupant les moyens d'acquisition et de restitution d'images du corps humain, selon plusieurs phénomènes physiques tels l'absorption des rayons X, la résonance magnétique et la réflexion d'ultrasons.

Utilisée à des fins cliniques, l'imagerie médicale existe afin de pouvoir déterminer avec précision le diagnostic des maladies, suivre leur évolution et proposer le traitement adéquat pour chaque pathologie.

Dans la médecine, il existe un certain nombre de techniques d'imagerie chacune d'elles, est sensible à un type de contraste particulier et s'applique pour des organes différents.

Les outils d'imagerie souvent utilisés pour le dépistage et le diagnostic du cancer du sein, sont généralement : l'échographie (par ultrasons), l'IRM (par résonance magnétique) et la mammographie (par rayons X) [23].

1.4.1 Imagerie par résonance magnétique mammaire

L'IRM mammaire est une technique d'imagerie médicale, qui utilise des ondes radiofréquences et des aimants puissants (champ magnétique). Cette méthode consiste à faire vibrer les atomes d'hydrogène du corps (figure 1.12), afin de produire un signal qui est traduit par un système informatique en images détaillées, montrant l'intérieur du sein.

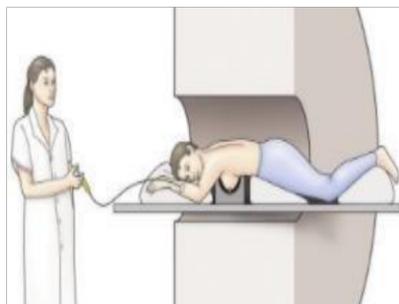


Figure 1.12 : Schéma d'installation d'une patiente [26]

Ayant pour but de préciser l'extension locale d'une lésion, lorsque le bilan conventionnel est insuffisant, l'IRM (figure 1.13) ne remplace ni la mammographie ni l'échographie mammaire. Elle est toutefois employée pour certifier l'absence de malignité, lorsque l'échographie et la mammographie ne donnent pas de résultats concluants. Elle permet aussi de guider un prélèvement par biopsie, de différencier entre une anomalie bénigne et une anomalie cancéreuse, lors du dépistage ; ceci revient aux images à haute résolution obtenues, à la fin de l'examen.

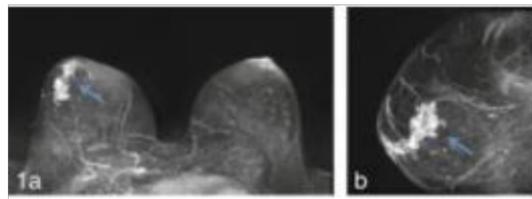


Figure 1.13 : Carcinomes intracanaux, prises de contrastes non-masses en IRM [26]

Etant certes très efficace, cette technique reste très coûteuse et n'est utile qu'à certains cas précis seulement (étude de prothèses mammaires en silicone, anomalies introuvables en mammographie et échographie, suivi de patientes opérées, etc) [24,25,26].

1.4.2 Mammographie

La mammographie est une technique de radiographie adaptée aux seins de la femme, à l'aide de faibles RX. Elle résulte en images démontrant l'intérieur du sein, pour détecter d'éventuelles anomalies au plus tôt avant de provoquer des symptômes cliniques.

La réalisation d'une mammographie se fait à l'aide d'un mammographe (figure 1.14). Dans un premier temps, les deux seins sont comprimés à tour de rôle, permettant l'étalement des tissus mammaires, pour faciliter la visualisation des structures du sein et ainsi, réduire la dose de RX délivrée. Ensuite, les deux seins sont exposés à de faibles RX, pour obtenir une projection sur un détecteur plan du sein.

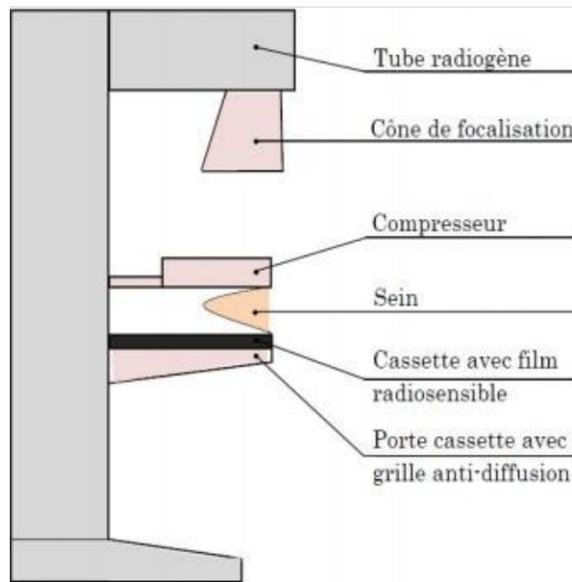


Figure 1.14 : Composants d'un mammographe [29]

En vue de son importance, l'examen mammographique est pratiqué soit dans le cadre d'un dépistage du cancer, ou d'un diagnostic.

La mammographie de dépistage expose des cancers de petite taille, au stade précoce, avant l'apparition des symptômes. Cet examen peut être réalisé soit par des femmes âgées de 50 à 75 ans ou à titre individuel, lorsque des facteurs particuliers se manifestent chez la femme. Elle peut être complétée par une échographie, pour analyser avec plus de détails la lésion.

La mammographie de diagnostic est réalisée lorsque la patiente a présenté des symptômes évoquant un cancer du sein. Elle comporte une mammographie de base et des clichés complémentaires centrés (figure 1.15), sur les zones suspectes. Elle peut être complétée par une échographie ou un prélèvement de l'anomalie [27,28,29,30].

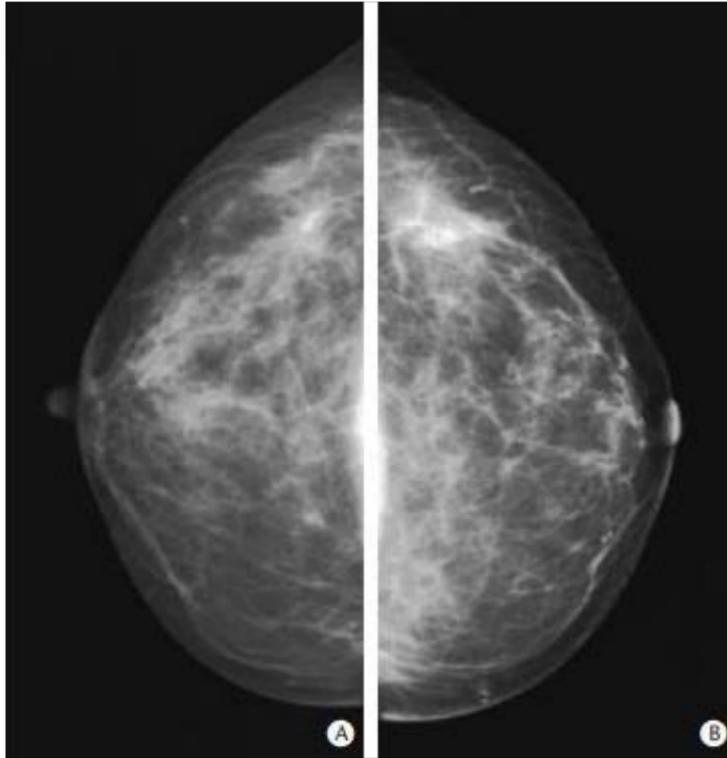


Figure 1.15: Images mammographiques : incidence de face droite (A) et gauche (B) [30]

1.4.3 Echographie

a Introduction

Malgré les nombreux avantages de la mammographie en termes de précision et de clarté, les cellules ne sont pas visibles surtout si le tissu mammaire est dense.

C'est pourquoi les chercheurs ont créé une modalité complémentaire qui s'appelle "l'échographie". Il a été publié que la première échographie dans le domaine médical, a été effectuée en 1952 par le britannique John Wild [31].

L'échographie mammaire est un examen médical sans contre-indication, qui permet de visualiser et observer le sein (figure 1.16), en employant des ultrasons. L'examen peut préciser la nature, liquide ou solide, d'une lésion dépistée à la mammographie [32].

Les avantages majeurs de cette technique, sont qu'elle est peu coûteuse et indolore.

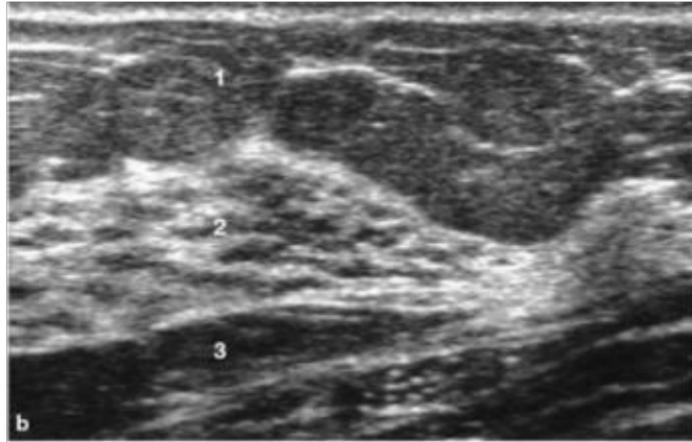


Figure 1.16 : Zones normales du sein en échographie [32]

b Principe de fonctionnement

L'échographie fonctionne à des fréquences très élevées. Au départ, la patiente est allongée sur le dos et torse nu. Après avoir effectué les palpations du sein, le gel hypoallergénique est appliqué sur la zone facilitant, le mouvement de la sonde. Dans ce cas, le radiologue positionne la sonde qui émet un courant électrique. Ce dernier entraîne des vibrations créant des ultrasons contre le sein, pour observer les tissus mammaires. Ensuite, le spécialiste commence à examiner tous les secteurs pendant moins de 30 minutes. Vers la fin, il prend les images échographiques résultantes des zones étudiées, ce qui permet d'orienter le médecin dans son diagnostic [32].

c Appareillage

L'échographie mammaire est un examen performant et d'une grande importance nécessitant un matériel haut de gamme, l'appareil à ultrasons (figure 1.17) ressemble à un ordinateur, il se compose :

-Des sondes : le cœur battant de cette machine, une sonde contient à l'intérieur des faisceaux piézoélectriques, elle permet de transmettre et de recevoir des ondes ultrasonores. Les sondes sont fragiles d'où la nécessité de les manipuler avec précaution [32,34].

-Un gel : un médiateur qui facilite et réduit l'atténuation du signal causé par la fine couche d'air entre la sonde et la peau pendant l'émission et la réception des ultrasons [32].

-Un système de visualisation : l'échographe suit l'examen sur l'écran [33].

-Un **système informatique** : il convertit le délai du processus entre la transmission et la réception des ultrasons en image [33, 34].

-Un **console de commande** : il représente un clavier pour différents réglages (la profondeur, le focale et le gain) et la saisie des données de la patiente [33, 34].

-Un **système d'enregistrement des données** : il sauvegarde l'examen en différente forme soit forme analogique comme (cassette vidéo, clichées) ou bien d'une forme numérique (format DICOM⁴) [33].



Figure 1.17 : Appareil d'échographie [33]

d Aspects échographiques des pathologies mammaires

Dans l'ultrasonographie, il existe des critères et des normes pour distinguer les différentes lésions [35] de façon précise (figure 1.18). Prenons le cas de :

- **Fibroadénome** : l'aspect des interstices foliaires, est soit oval ou divisé, en forme parallèle au niveau de la peau, ils sont entourés d'une fine capsule, sans changement de faisceaux postérieurs ou avec un renforcement discret, avec des ombres de diffraction latérales et compressibles. 95,4% des adénofibromes sont isoéchogènes⁵ , 3.1% sont très hypoéchogènes⁶ et 0.9% sont complètement ou partiellement hypoéchogènes.

⁴ **DICOM**: (Digital imaging and communications in medicine) est standard pour la gestion informatique des données issues de l'imagerie médicale

⁵ Isoéchogène : discrètement hypoéchogène

⁶ Hypoéchogènes : moins d'échogène que la graisse

- **Tumeur phyllode** : le contour n'est pas très net. Sa structure est hétérogène. Elle se présente comme une masse, qui peut être bosselée et grossir rapidement.
- **Papillome intra kystiques** : les ondes ultrasons détectent ces lésions, lorsqu'ils n'occupent pas les kystes complètement :
 - Papillome solitaire : s'il existe un nodule intracanalair écho-gène, le contour est limité au sein d'un canal et près du mamelon (<3 cm).
 - Papillome multiple, une masse hypogène, sa position est supérieure à 3 cm du mamelon.
- **Kystes** : ils se manifestent en échographie par une lacune anéchogène⁷, de contours réguliers avec une paroi fine et un renforcement postérieur.
- **Fibrose** : ou « Mastopathie fibreuse » ses aspects en échographie sont très variables. Parfois, cette pathologie apparaît sous forme d'une zone d'atténuation postérieure mais le plus souvent, sous forme de lacune de contours réguliers, d'où la nécessité des prélèvements.

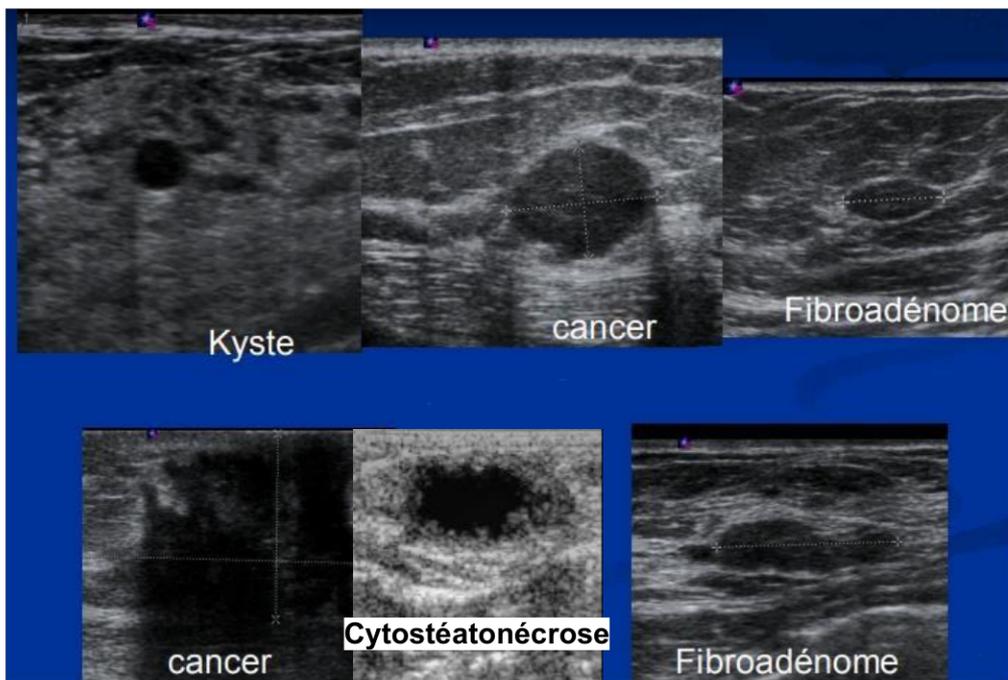


Figure 1.18 : Images échographiques des pathologies mammaires bénignes [9, 36]

⁷ Anéchogène : sans écho interne

1.5 Classification BI-RADS

La classification **BI-RADS** est l'abréviation de « Breast Imaging-Reporting and Data System ». C'est un système de classement d'images mammographiques, IRM et échographiques des lésions mammaires, publié et déposé par l'American College of Radiology (ACR). Cette classification permet de proposer une conduite à tenir adaptée. Son but consiste à standardiser les comptes rendus, afin d'améliorer l'évaluation, la prise en charge des anomalies mammaires, faciliter le suivi et la comparaison des lésions quelle que soit la cible d'images radiologiques [48].

Les tableaux 1.3 et 1.4, montrent le classement international.

Catégorie 0	Une imagerie complémentaire ou une comparaison avec les clichés antérieurs sont nécessaires (clichés localisés, agrandissement, incidence radiographique particulière, échographie, mais aussi IRM ou biopsie) ; il s'agit d'une catégorie d'attente alors que les autres sont finales.
Catégorie 1	Mammographie normale, rien à décrire.
Catégorie 2	Normale mais présence d'anomalie bénigne (fibroadénome, hamartome, lipomes, ganglions, cicatrices, calcifications bénignes).
Catégorie 3	Anomalie infraclinique, très probablement bénigne, dont la VPP est inférieure à 2 %, nécessitant une surveillance à court terme (masse solide, circonscrite non calcifiée, asymétrie focale de densité, calcifications rondes et punctiformes).
Catégorie 4	Anomalie suspecte à biopsier. Compte tenu de la large fourchette de la VPP (3 à 94 %), elle est divisée en trois sous-catégories (a, b, c).
Catégorie 5	Anomalie hautement suspecte de malignité (VPP \geq 95 %) pouvant être opérée d'emblée, mais la prise en charge oncologique peut nécessiter des prélèvements tissulaires (ganglion sentinelle, traitement néo-adjuvant).

Tableau 1.3 : Catégories d'évaluation BIRADS mammographique de l'ACR [37]

catégorie 0	les examens échographiques suspects effectués en première intention chez une femme jeune âgée de moins de 30 ans pour une masse palpable, ou si après traitement conservateur, on a des problèmes de diagnostic différentiel entre cicatrice et récursive.
catégorie 1	les examens échographiques sans anomalie.
catégorie 2	les constatations bénignes (kystes simples, ganglions, implants, fibro-adénome et cicatrices stables).
catégorie 3	les anomalies dont la VPP est inférieure à 2 % : masse solide circonscrite ovale et horizontale, kyste compliqué (échogène) ou dystrophie microkystique.
catégorie 4	les anomalies dont la VPP est comprise entre 3 et 94 %, nécessitant des prélèvements tissulaires.
catégorie 5	les anomalies de VPP > 95 % opérables d'emblée, en fait souvent la prise en charge oncologique nécessite des biopsies préalables (ganglion sentinelle, traitement néo-adjuvant).
catégorie 6	Les lésions dans la malignité a été prouvée par une biopsie.

Tableau 1.4 : Catégories d'évaluation BIRADS échographique de l'ACR [37]

1.6 Dépistage et Diagnostic médical

1.6.1 Dépistage

Par définition, le dépistage du cancer de sein est un test de surveillance prédictive, qui s'adresse aux femmes présumées indemnes de cette tumeur et ses symptômes, dans le but d'arriver à détecter des lésions à leur stade évolutif le plus précoce possible. En effet, selon les études sur l'impact des programmes de dépistage organisé, le pourcentage de réduction de la mortalité liée au cancer de sein, varie entre 3% et 35% [38].

Les cancers identifiés sont majoritairement de petite taille (53 % des cancers identifiés) ou des carcinomes in situ ⁸(17 %), ce qui confirme la qualité et la sensibilité élevée du dépistage d'une part, la possibilité de réduire le taux de mortalité lié au cancer d'une autre part, et donc sa grande efficacité pour améliorer les chances de guérison. [38,39]

⁸ Un cancer in situ correspond à une prolifération de cellules malignes sans rupture de la membrane basale, ne comportant pas de risque théorique d'envahissement ganglionnaire.

1.6.2 Diagnostic

Un bilan relativement à un diagnostic, doit donner une certitude diagnostiquée grâce à des examens spécifiques (mammographie, échographie, IRM...etc.) (figure 1.19). Il est plus sûr et précis que le test dépistage. En effet, le diagnostic du cancer de sein peut être fait dans le stade pré-symptomatique ; c'est à dire en l'absence de tout symptôme (dépistage), ou bien avant le stade symptomatique mammaire sélectionné par l'examen clinique (un nodule palpable, un écoulement mamelonnaire unipore, ou une maladie de Paget⁹ du mamelon) [39].

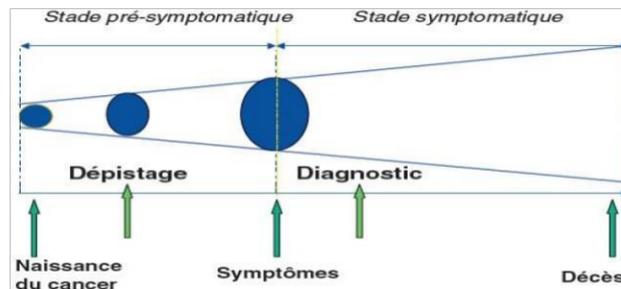


Figure 1.19 : Cinétique du cancer [39]

⁹ La maladie de Paget du sein est un type rare de cancer du sein. Elle apparaît sous la forme d'une éruption cutanée ou d'autres changements sur la peau du mamelon, habituellement sur un seul sein. La maladie de Paget du sein affecte davantage les femmes âgées de plus de 50 ans

1.6.3 Stratégie du diagnostic du cancer mammaire

Le médecin spécialiste, suit la démarche du diagnostic de la figure 1.20.

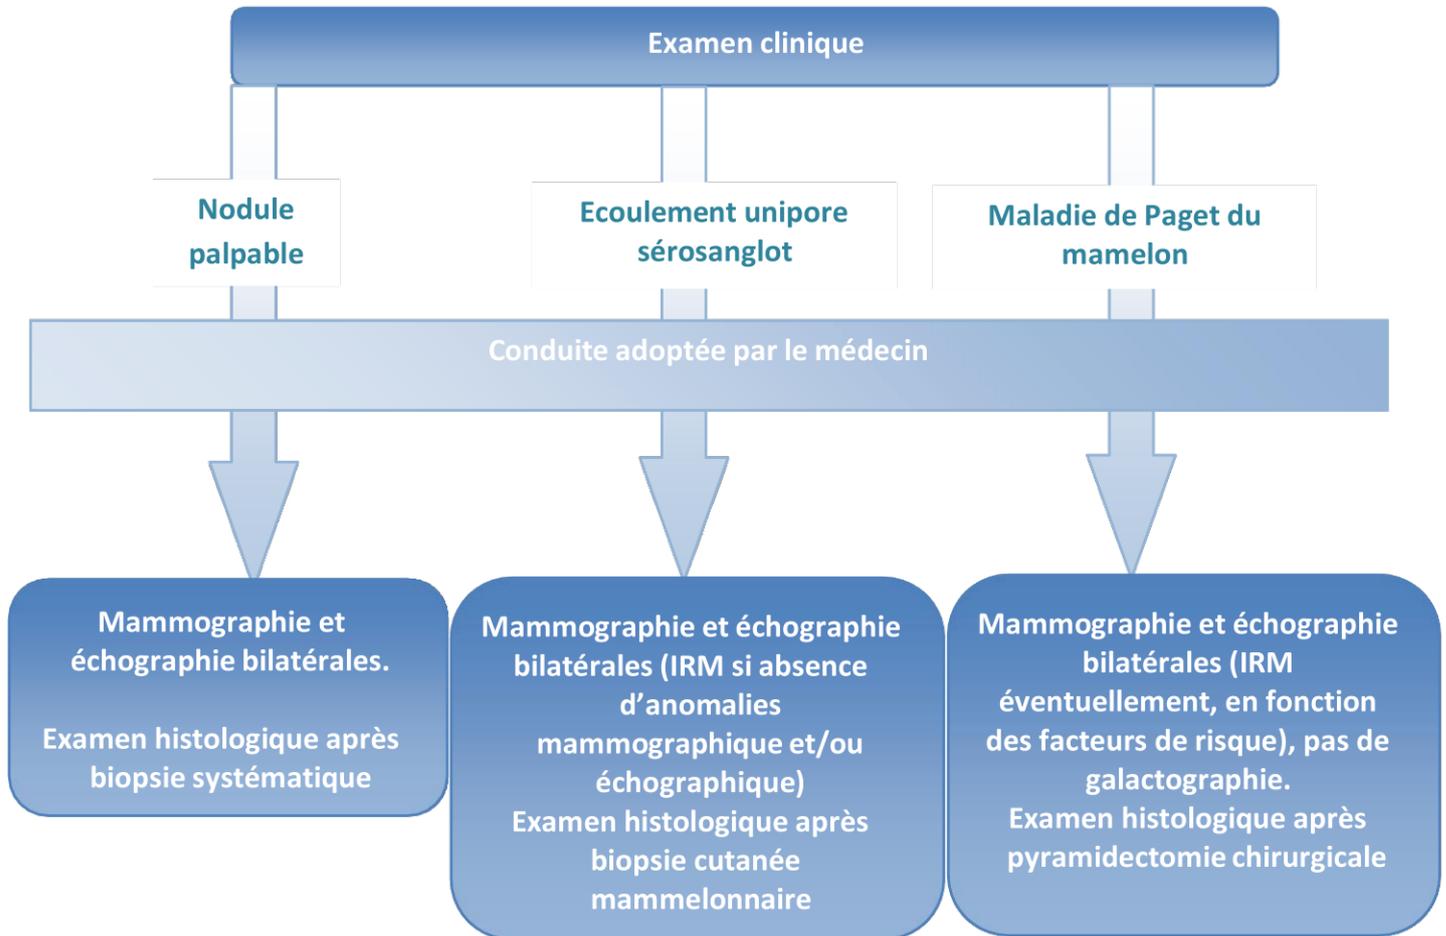


Figure 1.20 : Démarche stratégique du diagnostic du cancer du sein [38]

1.7 Introduction aux systèmes d'aide au diagnostic

1.7.1 Qu'est-ce qu'un système d'aide au diagnostic (CAD) ?

De manière simple et générale, les systèmes d'aide au diagnostic, sont des outils informatiques spéciaux qui guident les cliniciens et les radiologues, dans le diagnostic ou bien dans la décision thérapeutique. Ceci s'effectue par l'analyse des caractéristiques morphologiques des pathologies, dans le but d'améliorer la santé des patients et éviter certaines chirurgies superficielles inutiles. Le terme **CAD** recouvre aujourd'hui un ensemble d'outils informatiques et mathématiques variés, plus ou moins complexes [39].

1.7.2 Importance d'un système d'aide au diagnostic

Le traitement d'un volume important d'images mammographiques (plus de 150 images chaque jour), échographiques, ou d'autres types de radiologie, le manque d'expérience en imagerie médicale et la complexité décisionnelle du diagnostic, représentent les raisons pour lesquelles plusieurs recherches, se sont orientées vers l'intelligence artificielle et les systèmes informatiques. Ces systèmes se rapportent à deux applications principales :

- Les systèmes d'aide à la détection, permettent la détection et la localisation des lésions dans les images.
- Les systèmes d'aide au diagnostic désignent un système complet de traitement d'images mammaires, allant du prétraitement jusqu'à la classification et la prise de décision.

Le succès de tels systèmes est dû à leur rapidité, leur consistance et leur capacité à fournir des solutions fiables, pour assister l'étape de détection des lésions mammaires ou bien l'étape d'identification [40].

1.8 Conclusion

Ce chapitre nous a permis d'introduire quelques notions sur l'anatomie du sein, les différentes pathologies mammaires, ainsi que les outils de l'imagerie médicale effectuant le diagnostic du cancer, en l'occurrence l'échographie.

Malgré l'immense progrès des outils d'imagerie médicale ainsi que la compétence des médecins, le cancer du sein reste une maladie multifactorielle, d'où la difficulté à mettre en place, une stratégie de prévention afin d'éviter le dépistage. De ce fait, la détection du cancer du sein à un stade peu avancé de son développement, est primordiale pour limiter les séquelles liées à certains traitements abusifs et permettre de soigner le patient, plus facilement. Pour ce faire, notre projet, consistant en la détection précise des différentes masses mammaires, prend naissance, à travers l'apprentissage profond des images échographiques. Cela nécessite des connaissances approfondies dans le vaste domaine du Deep Learning, ce qui est l'objectif du second chapitre.

Chapitre 2

Introduction à l'apprentissage

automatique et profond

Chapitre 2 Introduction à l'apprentissage automatique et profond

Introduction

Etant loin d'être un nouveau sujet et prenant toute son ampleur, avec la disponibilité croissante des technologies, ainsi que l'augmentation exponentielle des puissances de calcul des ordinateurs, l'intelligence artificielle (ou l'IA) impacte de plus en plus, le quotidien personnel et professionnel de l'humanité.

Le terme Intelligence Artificielle, regroupe l'ensemble des théories et des techniques mises en œuvre, afin de concevoir des ordinateurs et des machines, permettant de simuler l'intelligence humaine. Elle permet à différents objets munis de systèmes informatiques, de réaliser des tâches qui jusque-là, étaient exécutées par des humains.

Parler de l'IA, implique systématiquement les termes de réseaux de neurones et d'apprentissage profond/deep learning.

Le deep learning, tout aussi présent, intervient chaque fois que nous cherchons un mot dans Google, une série sur Netflix, une vidéo sur YouTube ou, un produit sur Amazon. Grâce à l'apprentissage profond, des millions de cancers, peuvent être diagnostiqués chaque année ; des milliards de spams et de virus informatiques sont bloqués, pour protéger nos ordinateurs et sans lui, la voiture autonome n'existerait peut-être jamais.

Son application réussie dans différents domaines, a conduit à des débats et à des spéculations sur la question de savoir, si l'apprentissage profond pourrait être la clé pour réaliser l'ambition articulée par McCarthy et al [41].

Ce chapitre, introduit des concepts en relation avec l'apprentissage automatique et l'apprentissage profond.

Apprentissage automatique

Dès le 20^{ème} siècle et plus précisément, lors des années 1950, le concept de Machine Learning s'est vu naître, le mathématicien britannique, Alan Turing, imagina une machine capable d'apprendre qu'il nomma « Machine Learning » [42].

Au cours des décennies suivantes, **différentes techniques du Machine Learning**, ont été développées pour créer des algorithmes, capables d'apprendre et de s'améliorer de manière autonome.

En principe, les machines, les ordinateurs et les programmes, ne peuvent fonctionner que de la manière que nous avons configurée auparavant : « Si la situation A se produit, la B est activée ». Cependant, les attentes vis-à-vis des systèmes informatiques modernes, sont de plus en plus élevées et, les programmes ne peuvent pas prédire toutes les situations possibles, pour forcer des solutions informatiques. Par conséquent, il est nécessaire que le logiciel prenne des décisions indépendantes et réponde de manière appropriée, aux situations inconnues. Cependant, la disponibilité des algorithmes est nécessaire, afin de permettre aux programmes d'apprendre. Cela signifie que d'abord, il doit fournir des données et deuxièmement, il peut y être associé [43].

L'apprentissage automatique ou le *Machine Learning* (figure 2.1), est un domaine de l'intelligence artificielle, qui consiste à programmer une machine pour que celle-ci apprenne à réaliser des tâches, en étudiant les **données** de ces derniers. Le but du jeu en l'apprentissage automatique, est de trouver les paramètres A et B qui donnent le meilleur modèle possible. En résumé, le ML consiste à développer un modèle, en se servant d'un algorithme d'optimisation, pour minimiser les erreurs entre ce modèle et les données.

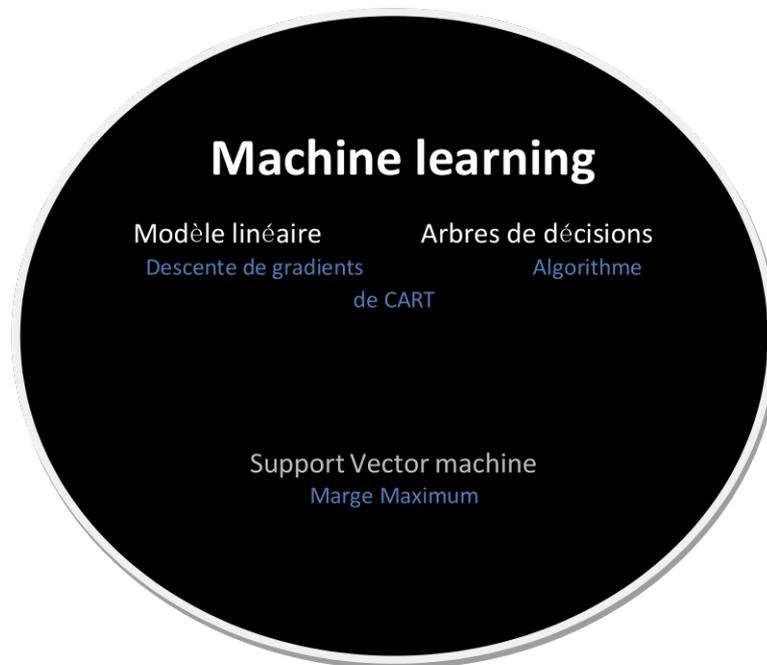


Figure 2.1 : Modèles développés par ML [43]

Méthodes d'apprentissage

Les principales méthodes d'apprentissage [44, 45, 46], se répartissent selon les types suivants :

a. Apprentissage supervisé

L'apprentissage supervisé (*supervised Learning*) est la méthode la plus utilisée, en Machine Learning. Le processus s'effectue en deux phases. Lors de la première phase (hors ligne, dite apprentissage), un modèle est déterminé à partir des données étiquetées. La seconde phase (en ligne, dite test), consiste à prédire l'étiquette d'une nouvelle donnée, connaissant le modèle préalablement appris.

L'apprentissage supervisé se base sur : le **dataset**, le **modèle et ses paramètres** (il peut s'agir d'un modèle linéaire ou bien non-linéaire), le **fonction de coût** et l'**algorithme d'apprentissage**.

L'objectif principal de l'apprentissage supervisé, se base sur la classification ou la régression des données (figure 2.2). Il permet ainsi, de trouver les paramètres du modèle, qui minimisent la fonction de coût pour réaliser les opérations avec une précision satisfaisante.

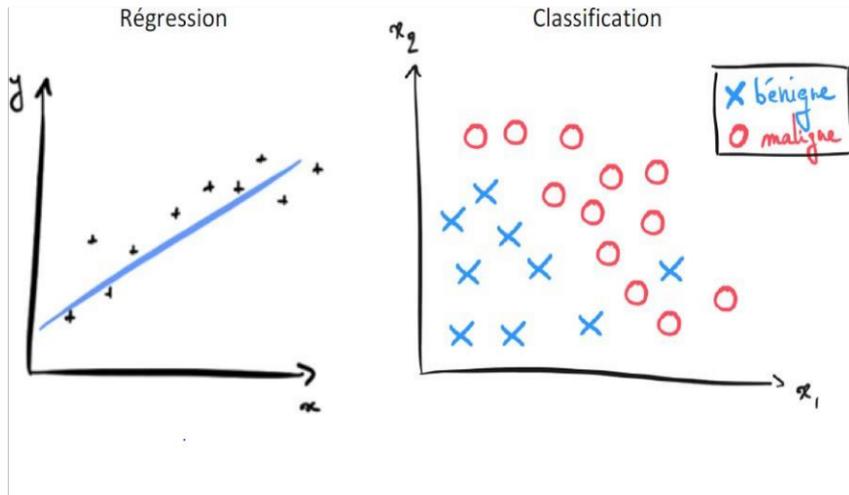


Figure 2.2 : Concept schématique de la classification et la régression [44]

b. Apprentissage non-supervisé

L'apprentissage non supervisé (*unsupervised learning*), désigne la situation d'[apprentissage automatique](#), où les données ne sont pas étiquetées. Le superviseur qui, dans l'apprentissage supervisé, indique toujours ce qui appartient et donne un retour d'informations, est éliminé. Dans ce cas, le programme essaie de reconnaître le modèle par lui-même. Il s'agit donc de découvrir les structures sous-jacentes, à ces données non étiquetées. Puisque les données ne sont pas étiquetées, il est impossible à l'algorithme de calculer de façon certaine un score de réussite [44].

c. Apprentissage par renforcement

L'apprentissage par renforcement (*reinforcement learning*), diffère fondamentalement des problèmes supervisés et non supervisés par ce côté interactif et itératif : l'agent essaie plusieurs solutions (on parle « d'exploration »), observe la réaction de l'environnement et adapte son comportement (les variables), pour trouver la meilleure stratégie (il « exploite » le résultat de ses explorations).

Un des concepts clés de ce type de problèmes, est l'équilibre entre ces phases d'exploration. Parmi les exemples de problèmes traités de cette façon, on peut évoquer : apprendre à un robot à marcher en terrain difficile, à conduire (cas de la voiture autonome) ou à accomplir une tâche spécifique [45, 46].

Descente de gradient

La descente du gradient, (DG : gradient descent en anglais) est un des algorithmes, les plus importants de tout le Machine et du Deep Learning. Il s'agit d'un algorithme d'optimisation extrêmement puissant (figure 2.3), qui permet d'entraîner les modèles de régression linéaire, régression logistique ou encore les réseaux de neurones. Il existe beaucoup de variantes de cet algorithme : Mini Batch Gradient Descent , Stochastic Gradient Descent , Momentum , RMSProp , Adam [44, 45].

Régression Linéaire: Résumé des équations

- **Dataset :** (x, y) avec m exemples
- **Modèle :** $f(x) = ax + b$
- **Fonction Coût :** $J(a, b) = \frac{1}{2m} \sum_{i=1}^m (ax^{(i)} + b - y^{(i)})^2$
- **Gradients :**
$$\frac{\partial J(a, b)}{\partial a} = \frac{1}{m} \sum_{i=1}^m x^{(i)} (ax^{(i)} + b - y^{(i)})$$
$$\frac{\partial J(a, b)}{\partial b} = \frac{1}{m} \sum_{i=1}^m (ax^{(i)} + b - y^{(i)})$$
- **Algorithme de Gradient Descent :**
$$\begin{cases} a := a - \alpha \frac{\partial J(a, b)}{\partial a} \\ b := b - \alpha \frac{\partial J(a, b)}{\partial b} \end{cases}$$

Figure 2.3 : Etapes d'entraînement d'un modèle de la régression linéaire par DG [44]

Métriques d'évaluation

Le choix des métriques [45, 46], représente une part importante de la mise en place de modèles d'apprentissage. D'une part, ce choix permet d'orienter la sélection d'un modèle en particulier et d'autre part, il permet de retenir les performances attendues par ce dernier, sur des données extérieures au jeu de données employé. L'un des principaux outils à disposition afin d'évaluer la performance, est la matrice de confusion, schématisée sur la figure 2.4.

Elle permet de faire correspondre les classes réelles et prédites. A cet effet, la diagonale de cette matrice, fait figurer les prédictions correctement réalisées par le modèle, tandis que les éléments restants, renseignent sur les prédictions erronées. Dans une situation à deux classes ou binaire, cette matrice fait ainsi ressortir quatre mesures :

- les vrais positifs, les éléments de la classe positive, détectés comme positifs ;
- les vrais négatifs, les éléments de la classe négative, détectés comme négatifs ;
- les faux positifs, les éléments de la classe négative, détectés comme positifs ;
- les faux négatifs, les éléments de la classe positive, détectés comme négatifs.

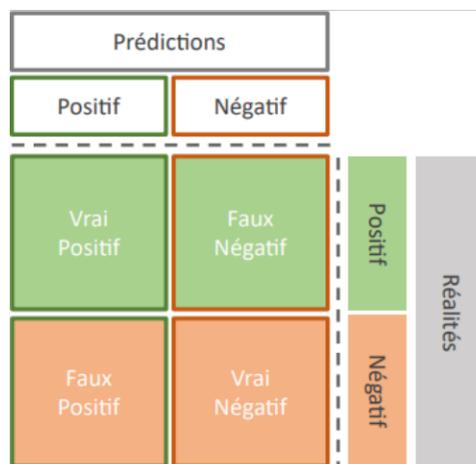


Figure 2.4 : Matrice de confusion d'une classification binaire [46]

Bien que déjà réduite, l'information de cette matrice est encore très riche et difficile à utiliser, comme critère de sélection. Pour cela, diverses métriques éprouvées, sont à envisager selon la problématique de recherche. Parmi les plus courantes d'entre elles, les critères de la précision, la sensibilité (également appelé rappel) ou la spécificité sont pléthores dans la littérature, mais ont tendance à ne capter qu'une partie du problème. Par exemple, la sensibilité est un critère très important en médecine, ou dans la détection de fraude, mais ne qualifie en rien la spécificité du modèle. De même, la moyenne fait également partie des critères extraits dans le domaine de l'intelligence artificielle, mais peut également manquer de sens, en cas de non balancement de l'information, ou même ne pas mettre en avant un important gouffre, entre la spécificité et la sensibilité. Ces métriques [46] sont représentées sous forme mathématique dans les équations 2.1, 2.2, 2.3 et 2.4.

$$\text{-Sensibilité} = \text{Rappel} = \frac{VP}{(VP + FN)} \quad 2.1$$

$$\text{-Specificity} = \frac{VN}{(VN + FP)} \quad 2.2$$

$$\text{-Precision} = \frac{VP}{(VP + FP)} \quad 2.3$$

$$\text{-Moyenne} = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad 2.4$$

Dans ce cas, il peut être préférable, de privilégier des métriques plus robustes, dans le cadre de données non balancées. La plupart des méthodes s'accordent sur l'utilisation de métriques, telles que le score F1, associant conjointement la sensibilité et la précision, par principe de la moyenne harmonique.

$$F\beta \text{ score} = (1 + \beta^2) * (\text{Precision} * \text{Rappel}) / ((\beta^2 * \text{Precision}) + \text{Rappel}) \quad 2.5$$

Une autre métrique permettant de se prémunir de ces effets de non balancement de l'information, est celui de l'AUC (Area Under the Curve) qui découle de la courbe ROC (Receiver Operating Characteristic), dont le principe est résumé sur le schéma Figure 2.5. La courbe ROC est tracée, à partir des informations de spécificité / sensibilité suivant la variation d'une valeur seuil, appliquée au modèle de prédiction ; tandis que, AUC (Aire sous la courbe, ASC) correspond à l'intégration de l'aire, de cette courbe. Ainsi, l'AUC est robuste au non-balancement de données, mais ses valeurs sont optimistes sur des modèles de prédiction, dont la variation du seuil est homogène vis-à-vis des résultats [46].

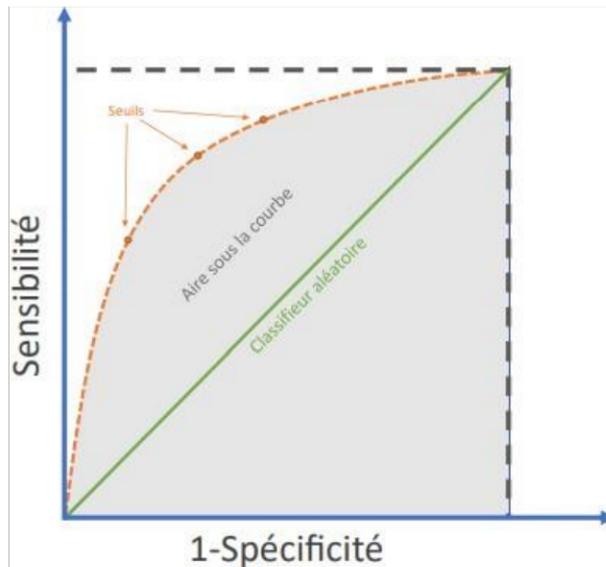


Figure 2.5 : Courbe ROC (en orange) et courbe AUC (en gris) [46]

Apprentissage profond

L'apprentissage profond ou bien « *deep Learning* », est une forme particulière du machine Learning (figure 2.6). Son principe reste exactement le même que l'apprentissage automatique (données, Modèle, Algorithme d'optimisation et Minimisation des erreurs) [47].

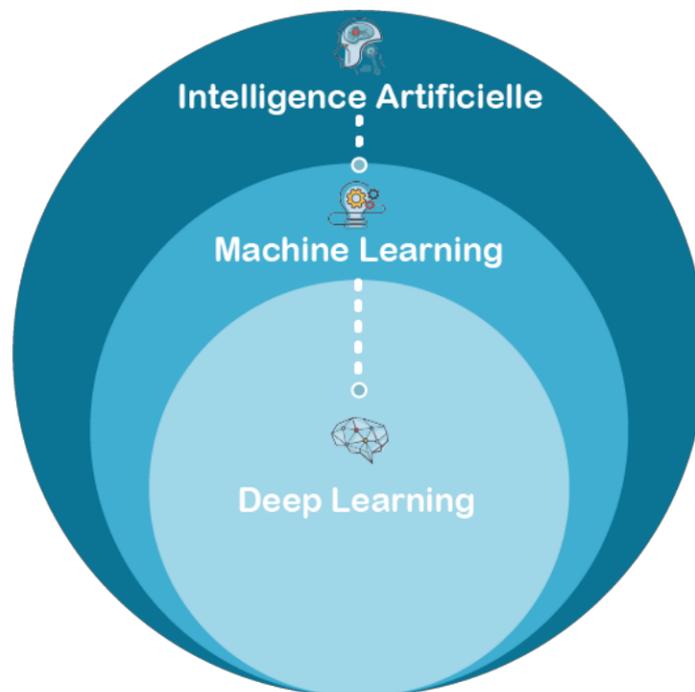


Figure 2.6 : Intelligence artificielle, apprentissage automatique et apprentissage profond [47]

Son modèle est un ensemble de fonctions connectées les unes aux autres, basé sur les « réseaux de neurones ». Plus le nombre de neurones est élevé, plus le réseau est profond.

Le cerveau humain est « profond », car chaque action est le résultat d'une longue série de communications synaptiques et, de multiples couches de traitement.

L'apprentissage profond regroupe une classe d'algorithmes d'apprentissage, correspondant à des architectures profondes. Il est souvent utilisé pour un apprentissage « de bout en bout », c'est-à-dire pour apprendre en même temps, les fonctionnalités utiles des données et comment les utiliser au mieux [47].

Par exemple, pour distinguer une voiture d'une moto, un algorithme peut apprendre à reconnaître les roues (une fonctionnalité utile), puis utiliser le nombre de roues pour les distinguer (à l'aide de cette fonctionnalité) [48].

Cela nécessite à la fois des connaissances en neurosciences, en mathématiques et dans les nouvelles technologies.

Le système se compose d'une série de modules (couches de neurones), dont chacun représente une étape de traitement. Chaque module est entraînable, avec des paramètres ajustables (semblables au poids d'un classificateur linéaire). Dans chaque exemple, tous les paramètres de tous les modules sont ajustés, pour rendre la sortie produite par le système plus proche de la sortie souhaitée. Le qualificatif « profond » vient de l'agencement de ces modules en couches successives.

Les réseaux convolutifs et les réseaux récurrents, sont les deux architectures les plus populaires, pour l'apprentissage en profondeur aujourd'hui [48].

Les progrès de l'apprentissage profond, ont été possibles notamment, grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« big data »).

La figure 2.7, représente la différence entre l'apprentissage automatique et profond.

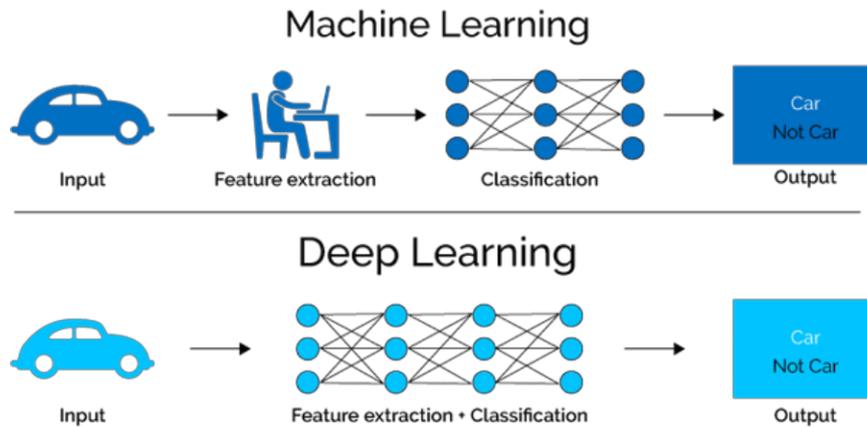


Figure 2.7 : ML Vs DL [49]

Histoire du DL

D'un point de vue anatomique, les neurones sont des cellules excitables connectées les unes aux autres et ayant pour rôle, de transmettre des informations, à notre système nerveux.

L'AP repose sur les différents réseaux de neurones artificiels, tels que, les RNP et les CNN, qui sont schématiquement inspirés, du fonctionnement des [neurones](#) biologiques (figure 2.8).

Le terme « deep learning » est assez nouveau, il apparut durant les années 2000. Son histoire débuta à partir d'une graine de "réseau de neurone", le terme a ensuite été plus développé au fil des années [47, 48].

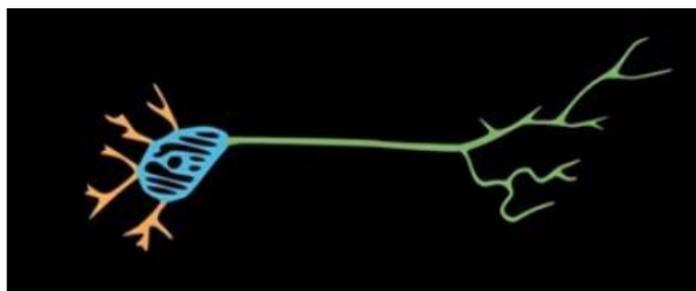


Figure 2.8 : Neurone biologique [50]

Le tableau ci-dessous, explique brièvement les étapes de développement du deep learning.

Année	Inventeurs	Invention	Explication
1943	Warren McCulloch Et Walter Pitts	« Invention de premiers neurones artificiels » et plus tard renommée «Threshold logic unit »	Les premiers réseaux de neurones sont inventés par deux mathématiciens et neuroscientifiques qui expliquent comment ils ont pu programmer des neurones artificiels en s'inspirant du fonctionnement des neurones biologique, Ils ont utilisé une combinaison d'algorithmes et de mathématiques qu'ils ont appelées « logique de seuil » pour imiter le processus de pensée.
1950	Frank Rosenblatt	Invention de perceptron	Le psychologue américain Frank inventa le modèle linéaire« perceptron »,le premier algorithme de reconnaissance de formes, basé sur un réseau de neurones informatiques à deux couches. Il utilisa une simple addition et soustraction. Il a également proposé des couches supplémentaires avec des notations mathématiques, mais celles-ci ne seront réalisées qu'en 1975.Grace au perceptron il sera possible de construire des machines capable de lire, de parler, de marcher et même d'avoir une conscience.
1986	David Rumelhart	Invention Le perceptron multicouches	Les premiers réseaux de neurones n'étaient pas capables de résoudre des problèmes non

			linéaires alors David Rumelhart inventa le modèle de perceptron multicouche avec l'utilisation de la technique Back propagation.
1990	Yann LeCun	Réseaux de neurones convolutifs CNN (LeNet)	Le célèbre Yann inventa les premiers réseaux de neurones convolutifs, réseaux qui sont capable reconnaître et de traiter des images, en introduisant au début de ces réseaux des filtres mathématiques qu'on appelle convolution et pooling.
1997	Sepp Hochreiter et Jürgen Schmidhuber	Les réseaux de neurones récurrents (LSTMs)	Les réseaux de neurones récurrents sont une variante du perceptron multicouche qui permet de traiter efficacement les problèmes de séries temporelles comme la lecture de textes ou encore la reconnaissance vocale.
Mid-2000s	Geoffrey Hinton et Ruslan Salakhutdinov	Deep learning	Le terme « deep learning » commence à gagner en popularité après qu'un article de Geoffrey Hinton et Ruslan Salakhutdinov a montré comment un réseau de neurones à plusieurs couches pouvait être pré-formé une couche à la fois.
2012		L'expérience du chat	AP n'a réellement pris envol qu'en 2012 lors d'une compétition de vision par ordinateur nommée ImageNet, où une équipe de chercheurs menée par Hinton développa un réseau de neurones capable de reconnaître n'importe quelle image avec une meilleure performance que tous les autres algorithmes de l'époque.

Tableau 2.1 : Evolutions historiques du deep learning [47, 48]

Différence entre le Deep Learning et le Machine Learning

Le tableau 2.2, montre les différences entre l'apprentissage automatique et l'apprentissage profond.

	Machine learning	Deep learning
Organisation des données	Données structurées	Données non-structurées
Base de données	Contrôlable	>1million de données
Entraînement	Entraînement par l'humain nécessaire	Système d'apprentissage autonome
Algorithme	Algorithme modifiable	Réseau de neuronal d'algorithmes
Champ d'application	Actions simple de routine	Tâches complexes
Temps d'entraînement	De quelques minutes à quelques heures	Jusqu'à des semaines

Tableau 2.2. : Différence entre le deep et le machine learning [47]

Réseau de neurones artificiels

Les réseaux de neurones artificiels, sont une technologie basée sur des études menées sur le cerveau et le système nerveux (cf. figure 2.9). Ces réseaux émulent un réseau de neurones biologiques, mais ils utilisent un ensemble réduit de concepts issus de ces systèmes. Les modèles RNA, simulent l'activité électrique du cerveau et du système nerveux [50, 51].

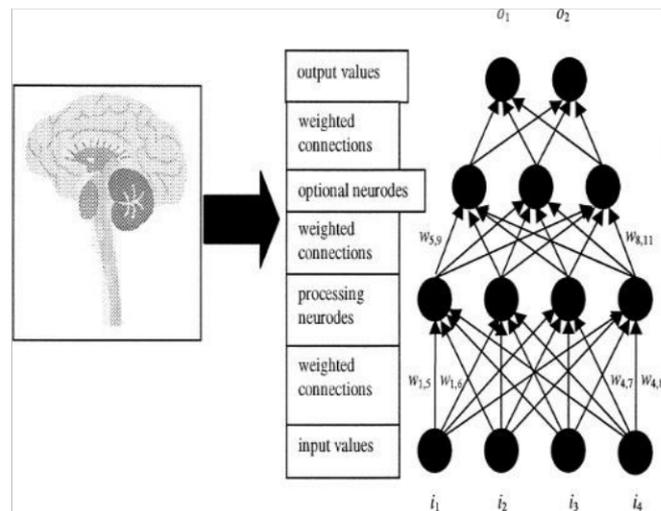


Figure 2.9 : Exemple d'un réseau de neurones artificiels [50]

Un réseau de neurones peut prendre des formes différentes, selon l'objet de la donnée qu'il traite ainsi que, selon sa complexité et la méthode de traitement des données [51, 52]. Cette capacité, permet d'entraîner la machine à effectuer des tâches plus avancées telles que :

- Reconnaissance d'objets et reconnaissance faciale.
- Analyse des sentiments.
- Analyse du langage naturel.
- Création artistique.

Principe de fonctionnement

Le neurone reçoit une ou plusieurs entrées (figure 2.10) à travers un neurone source, pour produire les classes désirées via une fonction d'activation. Ces entrées sont soit binaires, ou multiclassées [50, 51, 52, 53].

Le nœud réalise une somme pondérée des entrées, c'est la moyenne du nombre de valeurs affectées par des coefficients. Sa formule est représentée par :

$$Z_k^i = \sum_{n=0}^n (W_n * X_n) + b$$

2.6

Où : i : est le numéro de la couche suivante, k est le numéro de la couche actuelle, w est le poids et b , le biais.

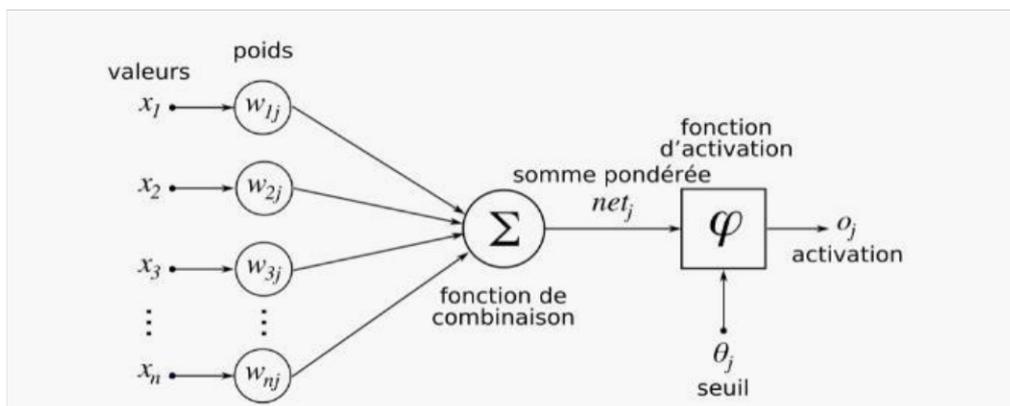


Figure 2.10 : Schéma d'un réseau de neurone artificiel [53]

Composantes principales du réseau neurones

Le réseau de neurones se compose de plusieurs couches, selon la figure 2.11.

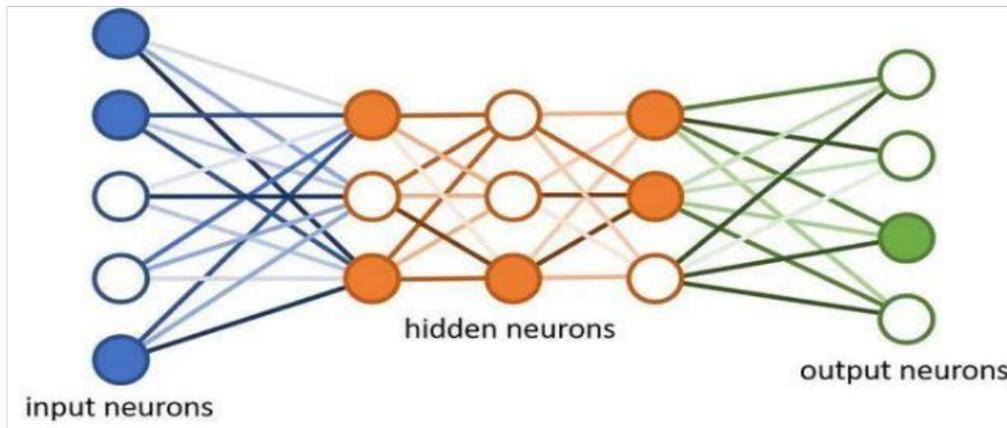


Figure 2.11 : Couches d'un réseau de neurones [52]

➤ Neurones

Les petits ronds indiqués sur la figure 2.10, sont **les neurones artificiels**. Ces neurones sont regroupés en couches, pour le traitement des entrées. Tous les neurones d'un même groupe, remplissent des fonctions similaires [53].

Les neurones d'entrée reçoivent les données d'entrée, les traitent et les transmettent aux neurones de la couche suivante. Les neurones cachés traitent les données de la sortie des neurones précédents en entrée, calculent les nouvelles données de sortie et les envoient, aux couches suivantes. Les neurones de la couche de sortie, produisent les sorties finales [53].

➤ Couches

Les couches (*Layers* en anglais), sont des regroupements de neurones qui aident à transmettre des informations. Deux couches au minimum, sont trouvées dans un seul réseau de neurones : la couche d'entrée (input layer) et la couche de sortie (output layer). Les couches, autres que les couches d'entrée et de sortie, sont appelées *les couches cachées (ou hidden layers)* [53].

➤ **Le poids et le biais**

Le poids et le biais, sont des variables du modèle, qui sont mises à jour pour améliorer la précision du réseau.

Le poids est appliqué à l'entrée de chaque neurone, pour calculer les sorties. Le réseau de neurones met continuellement, à jour ces poids. Par conséquent, une boucle de rétroaction est mise en œuvre, dans la plupart des réseaux de neurones.

Le biais représente l'erreur due à un modèle erroné, qui manque de précision et donne lieu à un 'Under fitting'. D'une manière simple, il représente le seuil d'activation d'un neurone. Par conséquent, les poids et les biais sont les valeurs d'auto-apprentissage de notre réseau de neurones [53].

➤ **Fonctions d'activation**

Les fonctions d'activations sont des algorithmes mathématiques appliqués, aux sorties. Lorsque les neurones calculent la somme pondérée des valeurs d'entrée, elles sont transmises à la fonction d'activation, qui vérifie si la valeur calculée est supérieure au seuil requis. Si la valeur calculée est supérieure au seuil, la fonction d'activation est activée et une valeur de sortie est déterminée [53].

Cette valeur de sortie est ensuite transmise aux couches suivantes ou précédentes (en fonction de la complexité du réseau), pour modifier le poids de leurs neurones et améliorer l'apprentissage.

Il existe un grand nombre de fonctions d'activation, telles que :

- **Fonction sigmoïde**

C'est fonction logistique (aussi appelé fonction sigmoïde ou tout simplement sigma). Elle est appliquée à la somme des entrées pondérées, par le poids W et le biais b . Cette fonction (2.6) a la particularité, d'être toujours comprise en 0 et 1. Elle est reproduite par une courbe en forme de S (fonction 2.10). Bien que de nature non linéaire, elle ne tient toutefois pas compte des légères variations des entrées, ce qui entraîne des résultats similaires [53].

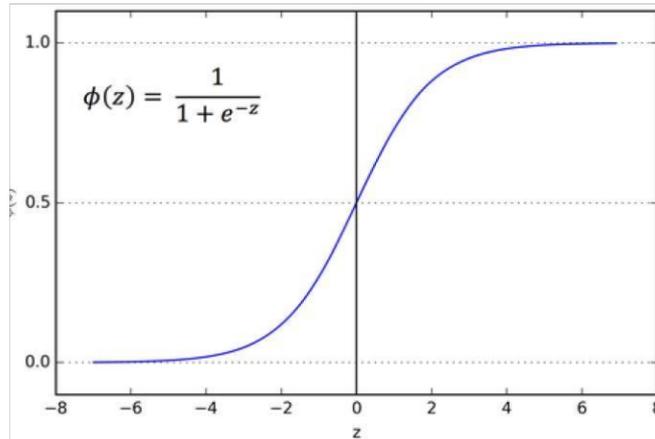


Figure 2.12 : Fonction logistique (Sigmoide) [53]

$$f(x) = \frac{1}{1 + e^{-x}}$$

2.6

- **Fonction tangente hyperbolique (tanh)** : Il s'agit d'une fonction supérieure (figure 2.13), comparée à la fonction sigmoïde. Cependant, elle rend moins bien compte des relations. Son inconvénient, est qu'elle est plus lente à converger [68].

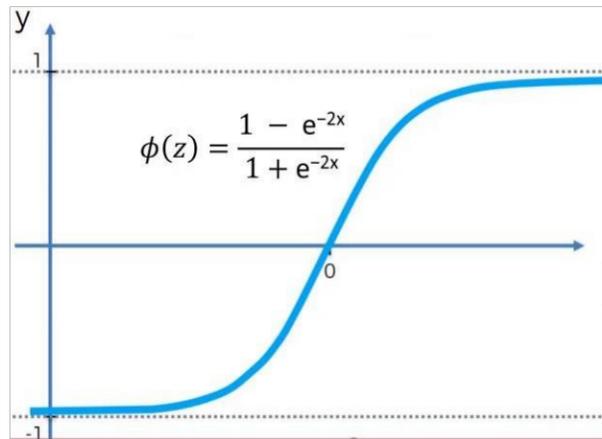


Figure 2.13 : Fonction tangente hyperbolique [53]

- **Unité linéaire rectifiée (ReLU)** : Cette fonction (figure 2.14) converge, optimise et produit la valeur souhaitée plus rapidement. C'est de loin la fonction d'activation (2.8), la plus populaire utilisée dans les couches cachées [53].

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$$

2.7

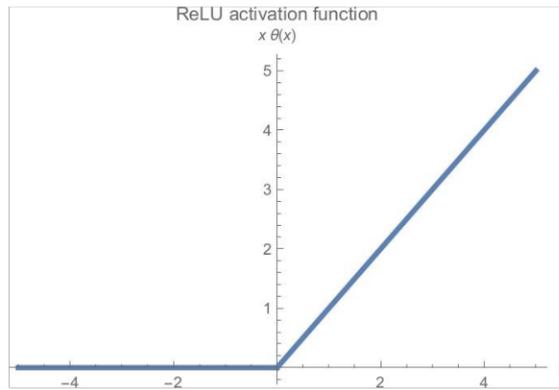


Figure 2.14 : Fonction ReLu [53]

- **Softmax** : cette fonction (figure 2.15) est utilisée dans la couche de sortie, car elle réduit les dimensions, pouvant représenter une distribution catégorique [53].

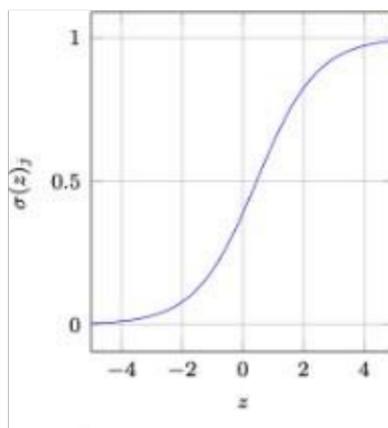


Figure 2.15 : Fonction Softmax [53]

Architecture des RNs

Les architectures de réseaux neuronaux [52, 53] [54,55] peuvent être divisées en 4 grandes familles :

Réseaux de neurones feed-forwarded

Feed-forwarded fait tout simplement référence, à la procédure du traitement des données, par le réseau neuronal. En effet, feed-fowarded (propagation avant) signifie tout simplement que la donnée traverse le réseau d'entrée à la sortie, sans retour en arrière de l'information. Typiquement, dans la famille des réseaux à propagation avant, il y a les réseaux monocouches (perceptron simple) et les réseaux multicouches (perceptron multicouche) [54, 55].

Perceptron simple

Le perceptron simple (figure 2.16) est la brique élémentaire du départ, qui a permis l'invention des premiers réseaux de neurones. Il est composé de deux couches (la couche d'entrée et la couche de sortie). Ces couches comprennent, un nombre de nœuds interconnectés par liaisons directionnelles. Il s'agit d'un modèle de classification binaire, capable de séparer linéairement deux classes de points [54].

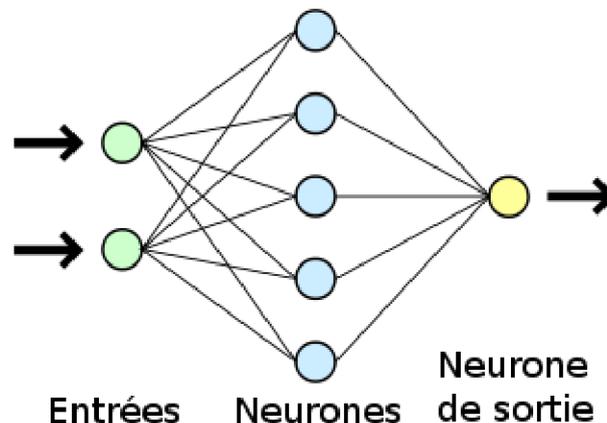


Figure 2.16 : Perceptron simple [54]

Réseaux de neurones multicouches MLP

Le perceptron multicouche (*multilayers perceptron*), est le premier réseau de neurones (figure 2.17) à avoir trouvé de nombreuses applications pratiques, telles que la reconnaissance d'images médicales, la détection de fraudes, etc... Il peut être utilisé pour toutes les tâches de la classification supervisée. Dans ce réseau, les neurones de la première couche, reçoivent toutes les informations des entrées, ceux de la deuxième reçoivent toutes les sorties des neurones de la première couche et ainsi de suite, jusqu'au neurone de sortie qui reçoit celles de la dernière couche [53, 55].

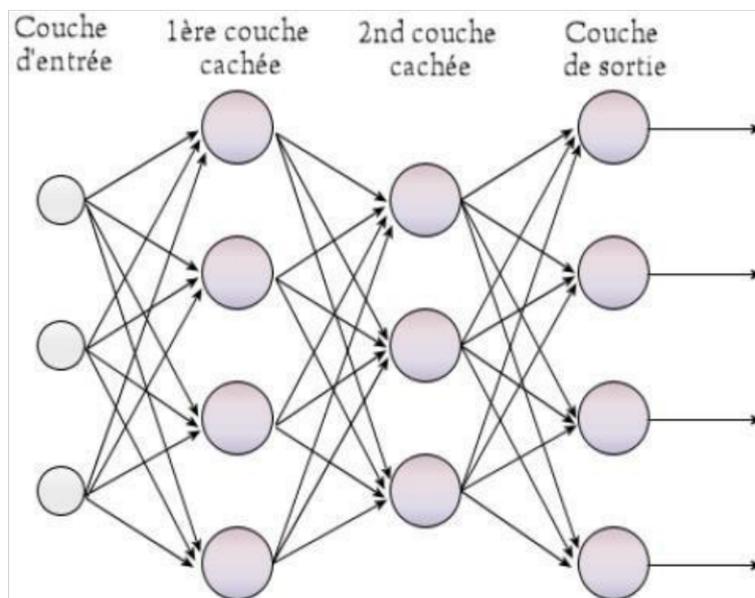


Figure 2.17 : Schéma du perceptron multicouche [55]

Réseaux de neurones récurrents

Les réseaux de neurones récurrents (ou RNN pour Recurrent Neural Networks), sont des réseaux de neurones dans lesquels, l'information peut se propager dans les deux sens ; de la couche profonde à la première couche. À ce stade, ils sont plus proches de la véritable fonction du système nerveux, qui n'est pas unilatérale.

Ces réseaux (figure 2.18) ont des connexions répétitives dans le sens, où ils gardent des informations en mémoire : ils peuvent considérer à tout moment, un certain nombre d'états passés.

Les réseaux de neurones récurrents se composent d'une ou plusieurs couches. Le modèle de Hopfield (réseau temporel) est le réseau de neurones récurrent d'une seule couche le plus connu [53].

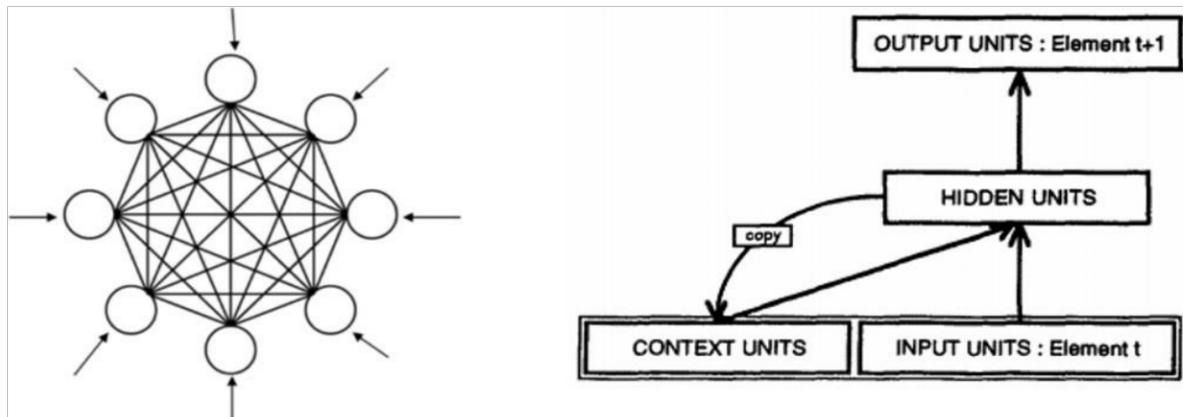


Figure 2.18 : Réseaux de neurones récurrents [53]

Réseaux de neurones à résonance

Une nouvelle fois, l'appellation du réseau neuronal fait référence à son fonctionnement. L'activation de tous les neurones, est renvoyée à tous les autres neurones du système. Ce renvoi provoque des oscillations, d'où la raison du terme résonance. Ces réseaux de neurones, peuvent prendre différentes formes, avec des degrés de complexité plutôt élevés, telles que le modèle ART (Adaptative Resonance Theory) (figure 2.19), qui fait interagir une information contextuelle avec la connaissance, que l'on a déjà, pour identifier ou reconnaître des objets. [53].

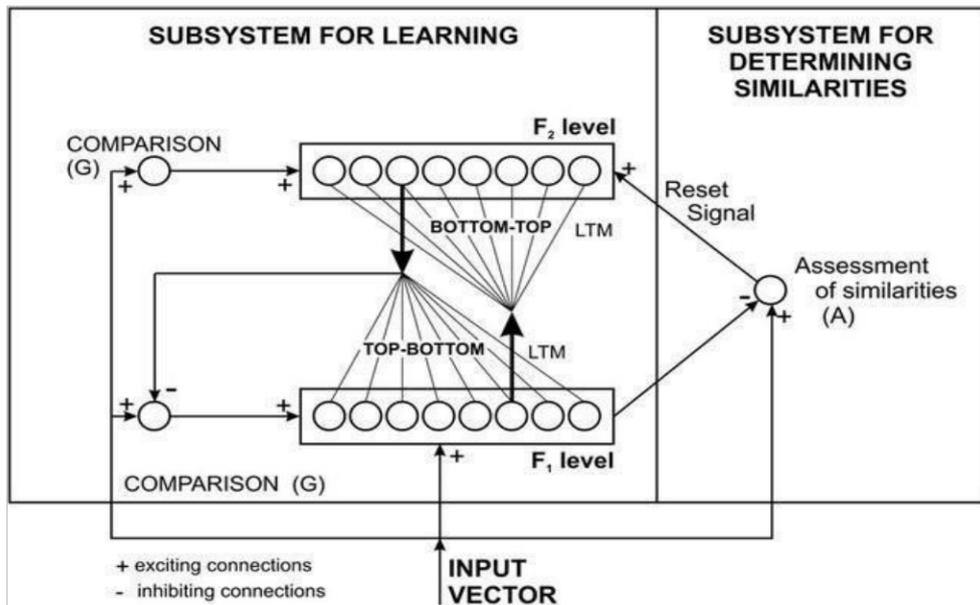


Figure 2.19 : Modèle ART [53]

Réseaux de neurones auto-organisés

Les réseaux de neurones auto-organisés, sont particulièrement adaptés au traitement de l'information spatiale. Grâce à des méthodes d'apprentissage non supervisé, les réseaux de neurones auto-organisés, peuvent étudier la distribution de données dans de grands espaces, tels que les problèmes de clustering ou de classification [53].

Le modèle le plus connu de ce type de réseaux de neurones est la carte auto-organisatrice de Kohonen (figure 2.20).

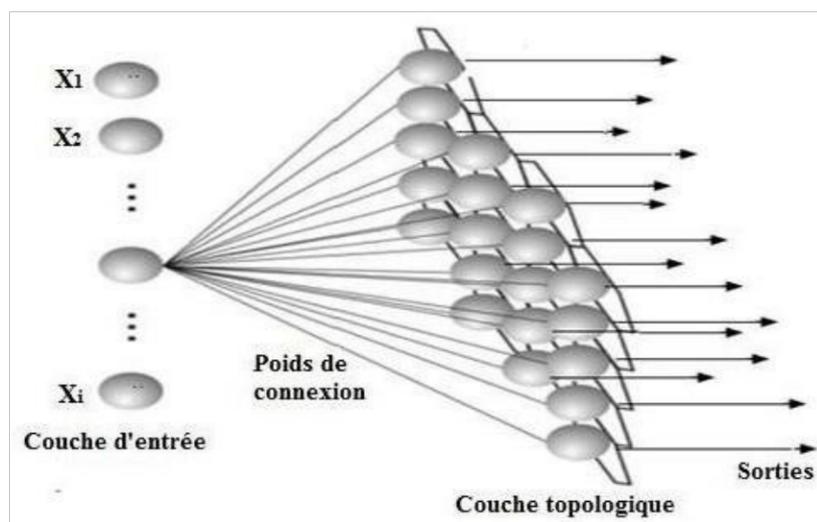


Figure 2.20 : Carte auto-organisatrice de Kohonen [53]

Réseaux de neurones convolutifs CNNs

Les réseaux de neurones convolutifs, ou réseaux de neurones à [convolution](#) (en anglais *CNN* ou *ConvNet* pour *Convolutional Neural Networks*), sont des [réseaux de neurones artificiels](#) acycliques (feed-forward). Ces types sont, à ce jour, les modèles les plus performants, pour la classification d'images. Désignés par l'acronyme CNN, ce sont des réseaux de neurones artificiels, qui s'appuient sur l'apprentissage profond, afin d'effectuer des tâches descriptives et génératives.

Leur fonctionnement est inspiré par les processus [biologiques](#). Ils consistent en un empilage multicouche de [perceptrons](#) (figure 2.21), dont le but est de prétraiter de petites quantités d'informations. Ils comportent deux parties bien distinctes.

En entrée, une image est fournie sous la forme d'une matrice de pixels. Elle a deux dimensions pour une image aux niveaux de gris. La couleur est représentée par une troisième dimension, de profondeur 3, pour représenter les couleurs fondamentales [Rouge, Vert, Bleu]. Son principal objectif est de réduire la quantité de calcul, pour faciliter l'apprentissage des données [56, 57, 58].

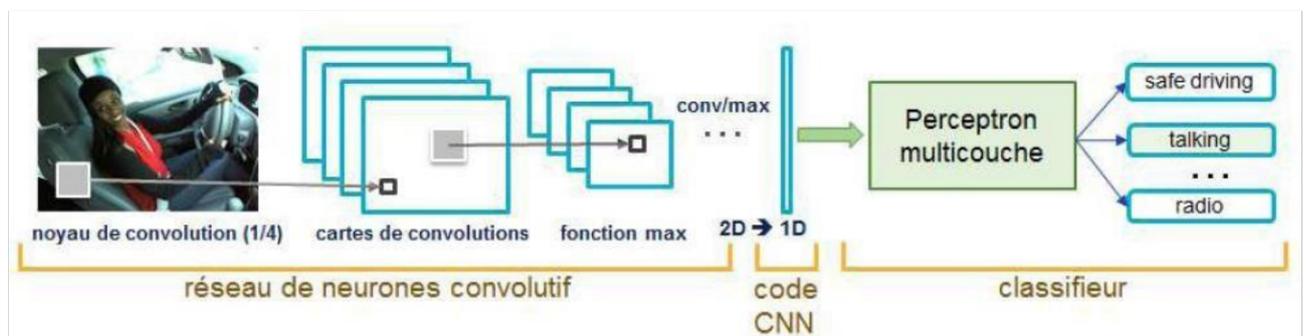


Figure 2.21 : Réseau de neurones convolutifs [56]

Architecture des CNNs

L'architecture du réseau de neurones convolutif CNN, est formée par un empilement de couches de traitement indépendantes. Un bloc de traitement se compose d'une à plusieurs couches [56, 59, 60].

Couche convolutive (CONV)

Pour le traitement des données de champ reçues ; la couche convolutive (figure 2.22) est un élément essentiel des CNN. Elle constitue leur première couche du réseau. Son but est de repérer l'existence des caractéristiques, dans l'image d'entrée [56, 59, 60].

Un filtrage par convolution, est effectué pour extraire une carte d'activation, qui définit la position des caractéristiques de l'image. Ainsi, plus la valeur est élevée, plus l'endroit correspondant est affecté aux attributs pertinents.

Le volume de cette couche est déterminé par trois hyperparamètres :

-**La profondeur** de la couche : c'est le nombre de noyaux de convolution (ou nombre de neurones, associés à un même champ récepteur).

-**Le pas** contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs, se chevauchent et plus le volume de sortie sera grand.

-**Le zero padding ou la marge.** Il est commode de mettre des zéros, à la frontière du volume d'entrée. La taille de ce 'zero-padding' est le troisième hyperparamètre. Cette marge permet de contrôler la dimension spatiale, du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface, que celle du volume d'entrée.

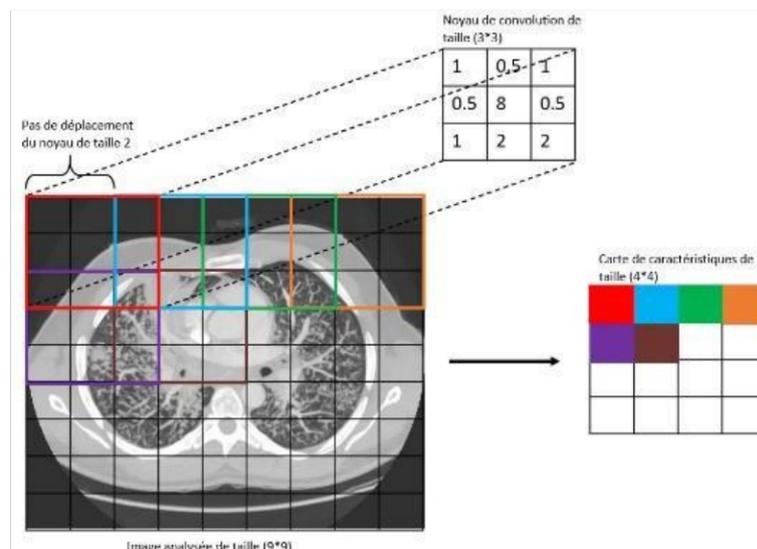


Figure 2.22 : Schéma d'une convolution avec un noyau de taille 3*3 et un pas de 2 [56]

Couche de correction (ReLU)

La couche de correction, est l'application d'une fonction non-linéaire aux cartes de caractéristiques, en sortie de la couche de convolution [60]. La couche de correction ReLU remplace donc, toutes les valeurs négatives reçues en entrée, par des zéros. Souvent, la correction Relu est préférable, car il en résulte la formation d'un réseau neuronal plusieurs fois plus rapide, sans faire une différence significative à la généralisation de précision. Elle est basée sur la fonction Relu, déjà définie dans la section 2.4.2.

Couche de mise en commun (pooling)

C'est une forme de sous-échantillonnage, qui permet de prendre une grande image et de réduire sa taille, en conservant les informations les plus pertinentes, réduisant de ce fait, la quantité de paramètres et de calcul dans le réseau [56, 60].

Généralement, une couche de pooling est insérée régulièrement, entre les couches de correction et de convolution.

En créant une invariance par translation, la couche de pooling rend le réseau moins sensible, à l'emplacement des caractéristiques. Que les caractéristiques soient plus hautes ou plus basses, la classification d'images ne change pas.

La couche de pooling fonctionne indépendamment, sur chaque tranche de profondeur de l'entrée et la redimensionne uniquement, au niveau de la surface.

La forme la plus courante, est une couche de mise en commun avec des tuiles de taille 2x2 (largeur/hauteur), se déplace avec un pas de 2 et comme valeur de sortie la valeur maximale en entrée (figure 2.23). Ou plus communément appelée « MaxPool (2x2,2) » [60].

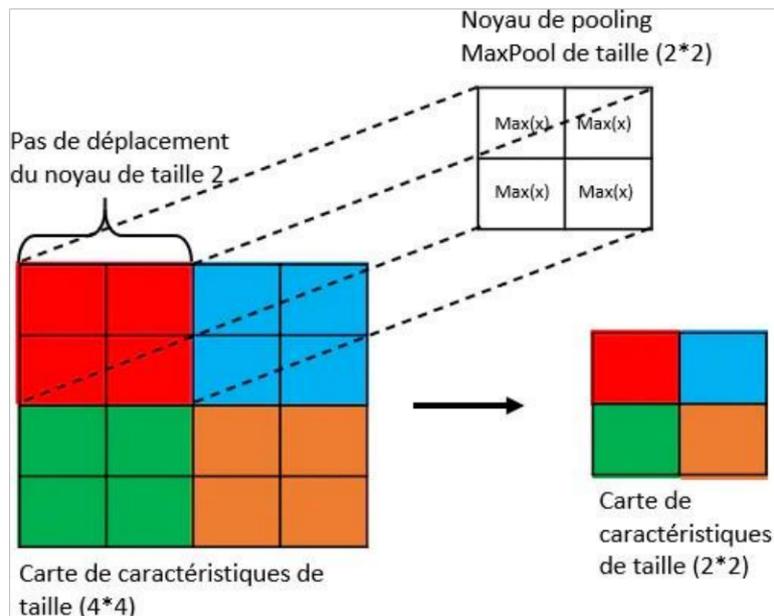


Figure 2.23 : Opération de pooling avec un noyau MaxPool de taille 2*2 et d'un pas de 2 [60]

Couche « Fully Connected »

La couche "entièrement connectée" (FC) (figure 2.24) est à la fin de réseau. C'est une couche de type perceptron. Dans ce cadre, le raisonnement de haut niveau dans le réseau de neurones, se fait à travers des couches entièrement connectées, car toutes les entrées de la couche sont connectées aux neurones des sorties de celles-ci. Ces couches, ont accès à la totalité des informations d'entrée. Le vecteur obtenu, contient les probabilités de classement pour chaque catégorie d'image [58, 60].

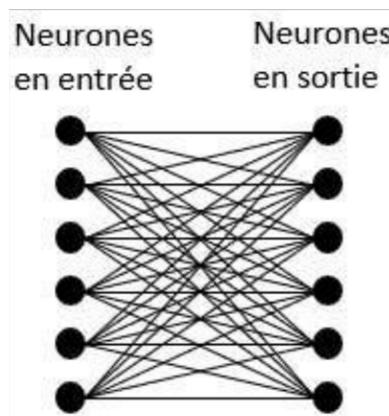


Figure 2.24 : Schéma d'une couche entièrement connectée avec 6 classes [60]

Couche de perte (LOSS)

La couche de perte est la dernière couche du réseau. Elle gère les ajustements de poids, sur le réseau. Avant le début de l'apprentissage, les poids de la couche convolutionnelle et de la couche FC, sont sous formes de valeurs aléatoires qui peuvent prendre uniquement, les valeurs 0 ou 1, représentant l'appartenance (1) ou non (0) à une classe. C'est pourquoi la fonction de perte la plus courante et la plus adaptée, est la fonction d'entropie croisée (2.8). Pendant le processus d'entraînement, la couche Loss vérifie en permanence les valeurs de la couche FC par rapport aux valeurs réelles afin de minimiser la différence entre l'estimation et la valeur réelle, en ajustant les poids de la couche FC et de la couche de convolution [58, 59, 60].

$$\text{loss}(x, \text{class}) = - \sum_{\text{class} = 1}^C y_{x, \text{class}} \log(p_{x, \text{class}}) \quad 2.8$$

où y est la probabilité estimée d'appartenance de x à la classe i . p est la probabilité réelle d'appartenance de x à la classe i , sachant qu'il y a C classes.

La manière dont s'enchaînent les couches de convolution, de correction et de pooling dans les blocs de traitement, ainsi que les blocs de traitement entre eux, rendent l'architecture du réseau unique.

Choix des hyperparamètres

Les hyperparamètres [58, 59] permettant de contrôler l'apprentissage automatique, en grande dimension. Les hyperparamètres peuvent être classifiés comme :

-**Les hyperparamètres des modèles** : qui ne peuvent pas être déduits, en [ajustant la machine à l'ensemble de l'entraînement](#), parce qu'ils s'appliquent à la tâche de la sélection du modèle. Les hyperparamètres permettent de définir la taille du réseau et son type.

Généralement, ces paramètres sont peu ou pas changés, car l'architecture est souvent utilisée telle qu'elle est proposée par son auteur, voire modifiée à la marge, dans le cas d'une stratégie de fine-tuning [56, 60].

-Les hyperparamètres d'algorithme : qui en principe n'ont aucune influence sur la performance du modèle, mais affectent la rapidité et la qualité du processus d'apprentissage. En deep learning, le modèle est encapsulé dans un algorithme d'apprentissage qui définit :

- Le chargement des données en entrée du modèle. L'opération est limitée, en fournissant la taille du 'batch size' en entrée du réseau et, la méthode de chargement avec ou sans échantillonnage.
- Le déroulement de la phase d'entraînement.
- Le déroulement de la phase de validation.

Dans ce dernier déroulement on remarque les paramètres suivants :

- Le nombre d'itérations, qui définit le nombre de cycles d'apprentissage (training-validation), que l'algorithme réalise pour permettre au modèle, d'améliorer ses estimations.

- La fonction de perte qui calcule la valeur de l'erreur existante, entre l'estimation et l'observation.

-L'optimiseur qui est la fonction d'optimisation utilisée, pour la descente du gradient.

-Le taux d'apprentissage, qui représente le pas, dans l'algorithme de la descente du gradient.

Les ConvNets utilisent plus d'hyperparamètres, que le MLP standard. Même si les règles habituelles du taux d'apprentissage et de constante de régularisation, s'appliquent toujours, il faut considérer le nombre de filtres, leur forme et la notion de forme de mise en commun maximale.

Avantages des CNNs

L'un des principaux avantages des réseaux convolutifs, est l'utilisation d'un poids unique associé aux signaux, qui pénètrent dans tous les neurones du même noyau de convolution. Cette méthode réduit l'empreinte mémoire, améliore les performances et permet la gestion de l'invariance du traitement par translation. C'est le principal avantage des CNNs, par rapport à MLP, qui lui, considère chaque neurone indépendant, il attribue donc des poids différents à chaque signal entrant. Lorsque le volume d'entrée change dans le temps (vidéo ou son), cela devient intéressant, d'ajouter des paramètres de délai dans le paramétrage des neurones [59, 60].

Apprentissage par transfert

L'apprentissage par transfert (Transfer Learning), désigne un ensemble de méthodes, qui peuvent transférer les connaissances acquises, en résolvant un problème donné à un autre problème.

Avec l'essor de l'apprentissage profond, l'apprentissage par transfert, a connu un grand succès. En effet, les modèles utilisés dans ce domaine, nécessitent souvent beaucoup de temps de calcul et beaucoup de ressources. Cependant, en utilisant des modèles pré-entraînés comme point de départ, l'apprentissage par transfert (figure 2.25) permet le développement rapide de modèles performants et de solutions efficaces, à des problèmes complexes de vision par ordinateur, ou de traitement du langage naturel [61, 62].

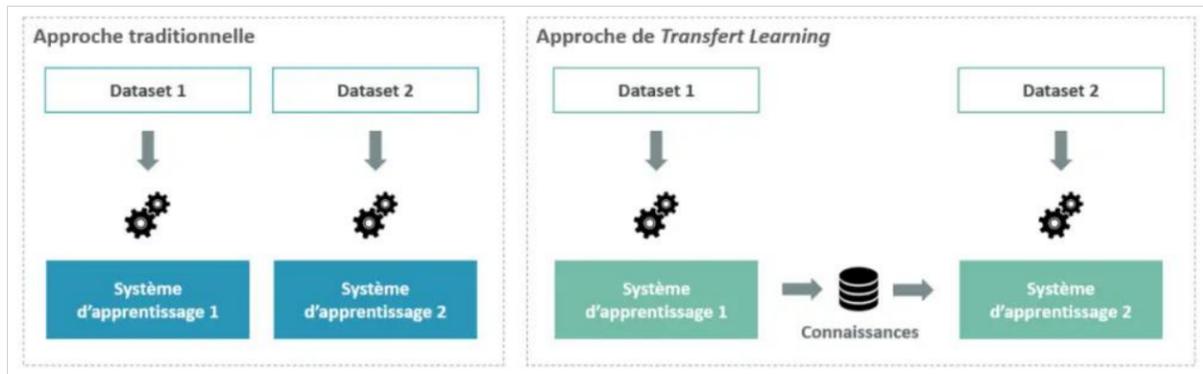


Figure 2.25 : Approche traditionnelle vs approche de transfer learning [62]

Description de Quelques travaux connexes réalisés en imagerie échographique

Nous décrivons dans cette section, quelques travaux explorés en imagerie ultrasonore du cancer du sein, dans la littérature scientifique et au sein de l'équipe d'imagerie du laboratoire LATSI.

Yap et al [63], proposent en 2008, une approche d'apprentissage profond, pour détecter les lésions des images échographiques mammaires. Les principales stratégies utilisées sont : une architecture **Patch-basedLeNet**, pour une classification binaire des lésions, un **U-net (FCN)** pour surmonter le besoin, d'utiliser un large ensemble de données et enfin un **Transfert Learning** basé sur le **FCN-AlexNet** pour une segmentation sémantique. Ils comparent et classifient deux ensembles de données d'images échographiques, acquis à partir de deux systèmes à ultrasons distincts, en des périodes différentes.

Dans ce cadre, les auteurs ont également exploré **quatre méthodologies de pointe, pour la détection des lésions en imagerie échographique du sein ; un filtrage par indice de gradient radial (RGI), un filtrage multifractal, un classement local basé sur des règles (RBRR) et les modèles déformables (DPM)**. L'ensemble de données A, contient un nombre total de 306 images, dont 60 malignes et 246 bénignes. L'ensemble de données B, quant à lui, comprend 163 images parmi lesquelles on compte 53 images malignes et 110 images bénignes.

En 2017, Han et al [64] présentent l'exploitation de techniques de l'apprentissage profond, pour distinguer les différents types des lésions du sein, à partir d'images échographiques. L'avantage principal des approches par apprentissage profond, est d'alléger le fardeau de la conception des caractéristiques spécifiées et de la classification, ainsi que la production directe des caractéristiques des images, depuis l'ensemble de données. Dans cette recherche, une structure d'un modèle de **GoogLeNet**, a été appliquée à un large ensemble de données d'images échographiques mammaires, fournissant un système **CADx** (est un système ayant pour but de classier les ROIs identifiés, qui sont obtenus à travers une segmentation manuelle ou par une détection automatique, à travers un système d'ordinateur de détection assisté) qui peut être utile lors des situations cliniques réelles. **GoogLeNet CNN**, est entraîné pour différencier les tumeurs malignes des bénignes. Pour un total de 7408 images échographiques mammaires, 6579 ont été utilisées comme un modèle d'entraînement et, 829 images comme ensemble de test. Le modèle d'entraînement est composé de 3765 images de masses bénignes et, 2814 images de masses malignes. L'ensemble des données utilisé pour le test, est composé de 489 images de lésions bénignes et 340 images de lésions malignes. L'initialisation a été effectuée par le modèle pré-entraîné **ImageNet**, qui a été ajusté pour obtenir de meilleures performances. Ce modèle est utile, lorsque le nombre de données entraînées n'est pas suffisant. Les paramètres optimaux ont été choisis, à partir de 10-fold cross validation avec le modèle d'entraînement. Les réseaux ont montré une courbe AUC supérieure à 90%, une précision de 91%, une sensibilité de 86% et une spécificité de 93%. Les résultats sont donc clairement prometteurs, pour cette méthode.

Al-Dhabyani et al [65], traitent la problématique d'augmentation des données et la classification des masses mammaires en échographie du sein, suivant des approches d'apprentissage profond.

A cet effet, Al-Dhabyani et al, utilisent une nouvelle méthodologie pour l'augmentation des données, à l'aide du Generative Adversarial Network (GAN) [46]. Le système développé use des CNNs pré-entraînés, avec et sans augmentation des données. Les résultats obtenus, confirment une amélioration de la classification des pathologies mammaires, grâce à l'augmentation des données.

Deux ensembles de données ont été utilisés : les Dataset BUSI et Dataset B. De plus, les auteurs les ont combinés, pour obtenir un troisième jeu de données (BUSI+B). Pour étudier l'impact de cette stratégie d'augmentation pour la classification, quatre expériences ont été menées. Tout d'abord, les CNNs et les modèles d'apprentissage par transfert ont été formés sur tous les ensembles de données, sous forme de référence. Deuxièmement, les mêmes modèles ont été formés avec le modèle traditionnel et troisièmement, par le GAN qui propose des techniques d'augmentation. Quatrièmement, par les deux formes d'augmentation (traditionnel et DAGAN). Les performances ont été évaluées sur les trois jeux de données (BUSI, B et BUSI+B). Le premier ensemble de données qui a été collecté à l'hôpital, au Caire (Égypte), appelé (BUSI), contient 780 images (133 normales, 437 bénignes et 210 malignes). Pendant que l'ensemble de données (B), est obtenu à partir de travaux connexes et contient 163 images (110 bénignes et 53 malignes).

Dans cet article, Chia-Yen Lee et al [66] rapportent que l'approche proposée, surmonte le problème d'inhomogénéité d'intensité dans l'échographie, en se basant sur plusieurs modèles des réseaux convolutifs pour la classification des tumeurs mammaires. Ils ont comparé cinq modèles d'apprentissages par transfert (SDAE, AlexNet, Inception v3, ResNet, DenseNet), pour déduire que le réseau SDAE, a obtenu la meilleure précision d'identification.

Comme il s'agit d'une petite quantité de données, SDAE est un choix pour analyser le petit ensemble de données. Les auteurs ont utilisé deux types de jeux de données. L'un est un ensemble de données privé (96 images malignes et 74 images bénignes) et l'autre, est un jeu de données public BUSIS (150 malignes et 100 images bénignes). Dans le jeu de données privé, 143 images sont sélectionnées au hasard comme données d'entraînement et 27 images, pour le test. Dans le jeu de données BUSIS, 210 images choisies au hasard, sont considérées pour l'entraînement et 40 images, pour le test. A cet effet, pour le jeu public, la précision est de 83%, alors que pour l'ensemble privé, la précision est de 82%.

Dans les travaux du laboratoire LATSI, Salem [67], les réseaux de neurones profonds pré-entraînés en l'occurrence VGG19, VGG16 et Inception V3, ont été traités ; ils exploitent l'enchaînement classique des couches de convolutions, de pooling et les blocs Inception. Le modèle adopté est affiné selon deux stratégies : le fine-tuning total et le fine-tuning partiel. Les résultats démontrent que l'Inception V3, surpasse le VGG16 et le vgg19, avec une précision de 94,64% et une AUC de 0,98.

Dans les travaux de l'équipe IMAD du laboratoire LATSI, Cherifi [68], l'étude de quatre architectures CNN différentes : RESNET, VGG16, VGG19, XCEPTION a été proposée, les architectures ont été appliquées sur deux bases de données échographiques, pour la catégorisation des classes malignes, bénignes et normales. Le système réalisé engendre une précision de 100% et une exactitude de 93%, pour une aide à l'interprétation.

Conclusion

Dans ce chapitre, nous avons introduit quelques notions sur l'apprentissage automatique, pour aborder le concept de l'apprentissage profond, le principe de son fonctionnement ainsi qu'une description générale sur les fonctions des réseaux de neurones convolutifs.

Le chapitre suivant présentera les modèles des réseaux convolutifs, sur lesquels, l'étude conceptuelle du système de la classification de lésions cancéreuses échographiques, est basée.

Chapitre 3

Conception du système d'aide à la classification de lésions cancéreuses du sein et modèles des réseaux convolutifs

Chapitre 3 Conception du système d'aide à la classification de lésions cancéreuses du sein et modèles des réseaux convolutifs

Introduction

Basé sur son système visuel ainsi que les images d'autres examens cliniques, le radiologue s'occupe de l'interprétation des résultats fournis, à partir d'images échographiques. La multitude de cas et de patients, rend l'interprétation plus lente et plus exposée à d'éventuelles erreurs.

Dans ce cadre, l'Intelligence Artificielle a grandement prouvé son efficacité dans ce domaine, grâce à des approches d'apprentissage automatique et d'apprentissage profond, dévoilant clairement les performances optimales des systèmes, via des réseaux de neurones convolutifs (CNN).

Dans ce chapitre, nous allons introduire les différentes architectures des CNNs, permettant la conception d'un système d'aide à la prise de décision, afin de distinguer les classes des pathologies mammaires à travers des images échographiques.

Conception d'un système d'aide à la détection et la classification des pathologies mammaires en échographie

Ayant pour objectif d'assister le radiologue dans le diagnostic, pour obtenir de meilleurs résultats, notre étude consiste à élaborer un système d'aide à la prise de décision (CAD), afin de détecter et classier les différentes pathologies mammaires, en utilisant des images échographiques. La conception de notre système est basée sur plusieurs architectures des CNNs, estimant les plus efficaces d'entre elles.

Architecture du système conçu

Suivant nos recherches sur le sujet étudié, nous avons constaté la similitude de l'architecture globale des approches utilisées, pour la classification des pathologies. Ces approches sont structurées en deux modules principaux, qui fonctionnant de manière indépendante ; qui sont l'extraction des caractéristiques pertinentes et la classification des images. Le schéma suivant (cf. figure 3.1) représente le modèle adopté avec plus de détails.

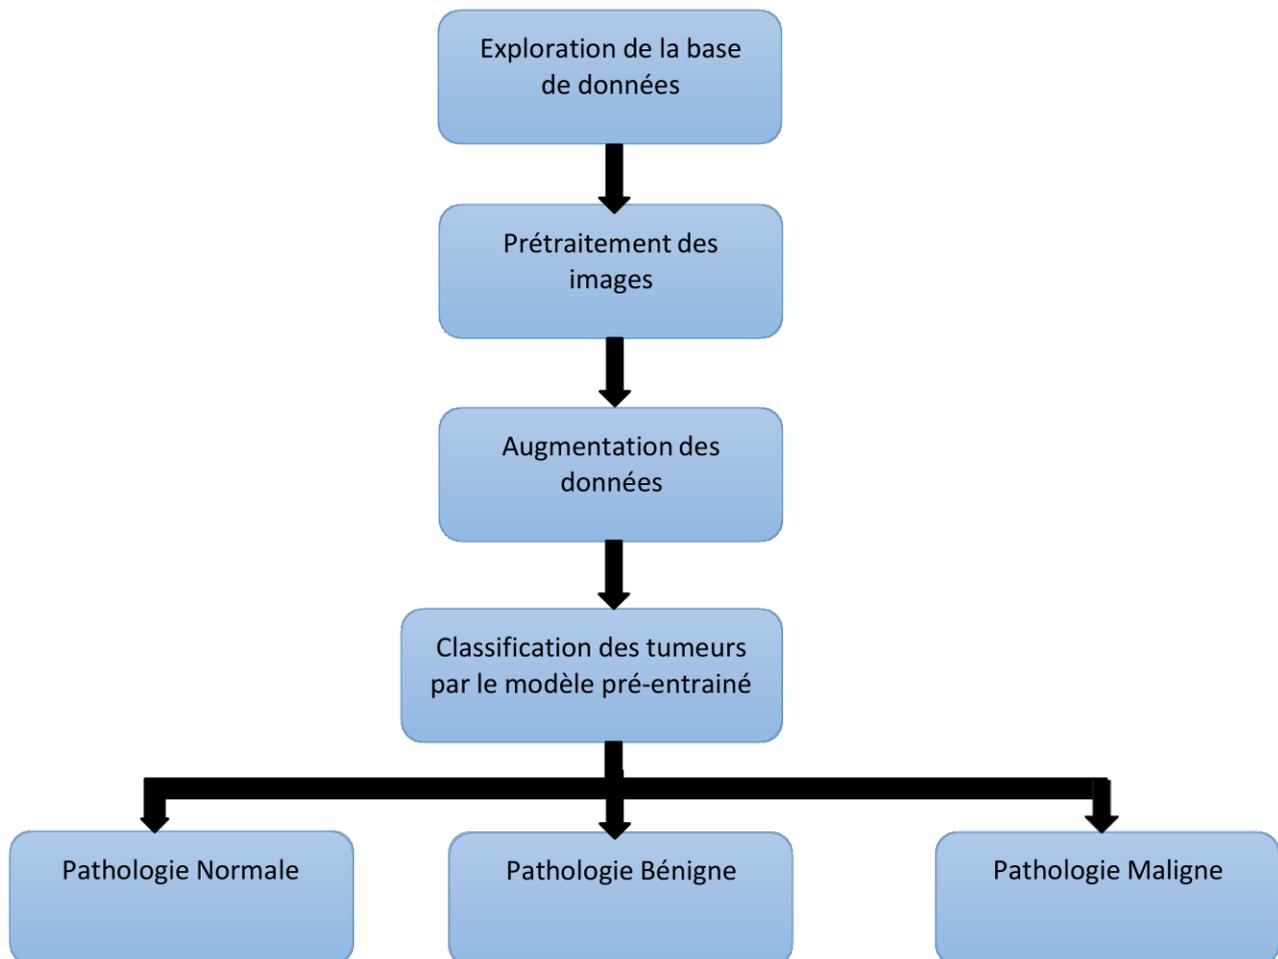


Figure 3.1 : Schéma du système CAD conçu

Après avoir introduit les images de la base de données, le système commence l'extraction des caractéristiques, convertissant ainsi, les données à des formats plus réduits, afin d'obtenir les informations les plus pertinentes, qui vont être utilisées lors de la classification.

Le processus de l'extraction est considéré comme une étape primordiale du système.

Basé sur une approche des réseaux de neurones convolutifs (CNNs), il adopte trois architectures pour la classification de la base de données (images échographiques des différentes pathologies mammaires) : le VGG16, l'Inception-V3 ainsi que le ResNet.

Suite à la recherche bibliographique effectuée, l'utilisation des modèles de CNNs conçus pour utiliser l'apprentissage par transfert, sera mise en avant, afin d'obtenir de meilleurs résultats en question de précision selon la base de données adoptée. En effet, l'application du concept d'apprentissage par transfert ou 'transfer learning', contribue à l'amélioration des résultats des hyperparamètres (l'augmentation de la précision du modèle, la réduction du temps entraînement...).

Le système étudié s'appuie sur les architectures des réseaux convolutifs pré-entraînés. Le premier modèle utilisé, est le VGG16, qui compte des couches de convolutions, de pooling, etc. Cette dernière réduit le nombre de couches de convolution, améliorant ainsi, le temps d'entraînement.

Une deuxième architecture est utilisée dans notre approche, plus moderne, comme l'Inception qui compte des blocs d'Inception, ainsi que le DenseNet, qui se montre utile, afin de référencer les caractéristiques, plus tôt dans le réseau. Une légère modification sera apportée aux architectures citées, où les dernières couches, sont remplacées par un nouveau classifieur, pour ensuite les affiner selon un fine-tuning total. Le principal but étant d'atteindre les meilleures performances, lors de la détection des pathologies.

Analyse de la base de données

La base de données explorée dans le cadre de ce projet, représentant des images échographiques mammaires, est d'origine égyptienne « DatasetBusi » (BreastUltrasound Images Dataset) [69]. Cette base de données est divisée en trois ensembles, où chacun d'eux, est utilisé pour une phase de création du modèle (figure 3.2).

- La base entraînement ou « training set », représente 80% de l'ensemble de données d'origine). Elle est utilisée pour entraîner le modèle choisi.

- La base de validation, représente 10% de l'ensemble des données originelles. Son objectif est de minimiser le sur-apprentissage.

Cette base permet de vérifier que chaque augmentation du pourcentage de bonne classification, par rapport à l'ensemble de données d'apprentissage, entraîne une augmentation du pourcentage de bonne classification, relative à l'ensemble de données non-testé.

- Si un sur-apprentissage survient, la précision du dataset d'entraînement augmente, mais la précision du dataset de validation reste la même ou diminue. Dans ce cas, il est primordial d'arrêter l'entraînement.

- La base de test ou « test set » se compose de 10% de l'ensemble de données d'origine. Lorsque le modèle termine l'entraînement, le dataset de test, est utilisé afin de vérifier les résultats finaux et, confirmer la précision du réseau.

Ignorer la phase de test est fortement déconseillé. En effet, l'absence de problème dans l'algorithme de classification, lors de la phase de validation, ne signifie pas forcément que le modèle choisi, est le plus adéquat à la problématique posée. Durant cette phase, le modèle final, est utilisé pour classifier de nouveaux échantillons. De ce fait, si la précision du modèle est mauvaise lors de la phase de test, la conception du modèle doit être remise en question.

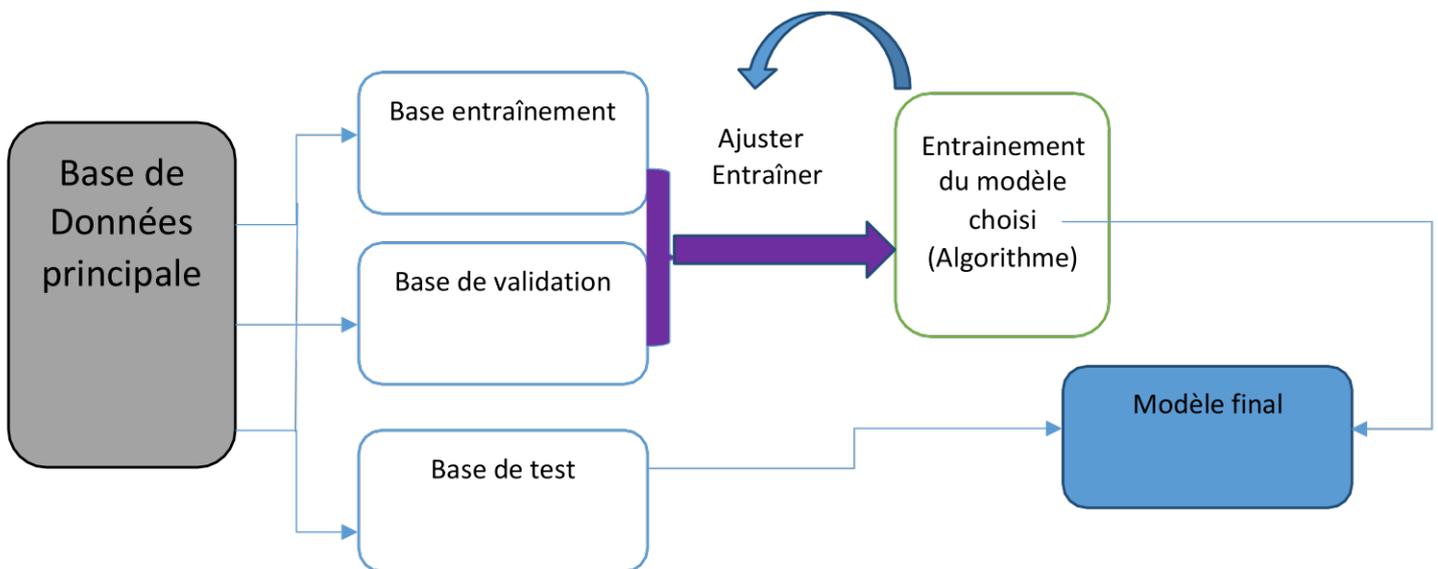


Figure 3.2 : Schéma désignant l'utilisation des datasets lors de la formation du modèle

Prétraitement des images

Les images mises à notre disposition, au sein de la base de données, sont sur différentes formes, résolutions et en niveaux de gris. Il est donc crucial de les redimensionner, à une taille 224x224 pixels, nous permettant aussi de gagner en espace mémoire. Par ailleurs, ce prétraitement des images, permet d'uniformiser les images à traiter, pour l'utilisation des modèles pré-entraînés.

Augmentation des données

La majeure partie des problèmes de la vision par ordinateur dans l'apprentissage profond, est l'insuffisance de données, d'où l'important usage de leur augmentation.

Une technique souvent utilisée, consiste à générer artificiellement de nouvelles données, en déformant les données primaires, à travers des transformations qui préservent l'information pertinente. Les opérations de cette technique, permettent d'améliorer la diversité des données d'entraînement d'un classifieur, dans le but de parfaire ses performances [70,71, 72].

a Méthodes courantes d'augmentation des données

La méthode la plus simple est **la mise en miroir des données**.

Dans le jeu d'entraînement, l'image est retournée horizontalement (cf. figure 3.3). Pour la majorité des tâches de ce processus, si l'image de gauche est un chat, la mettre en miroir donne toujours un chat. De ce fait, si la mise en miroir, préserve les informations pertinentes identifiées dans l'image, elle sera donc une technique d'augmentation imparable [77].



Figure 3.3 : Effet miroir [72]

Une seconde technique couramment utilisée, est **le recadrage aléatoire ou zoom aléatoire**.

En partant d'un ensemble de données, il est possible d'obtenir de nombreux recadrages aléatoires (figure 3.4), de l'ensemble de données initial, afin d'alimenter l'ensemble d'entraînement. Cependant, n'étant pas une technique parfaite, le recadrage aléatoire peut laisser surgir un certain problème, où s'il était trop petit, il provoquerait la perte de l'information pertinente. En pratique, il reste donc valable tant que les recadrages aléatoires, soient des sous-ensembles raisonnablement grands, de l'image réelle [72].

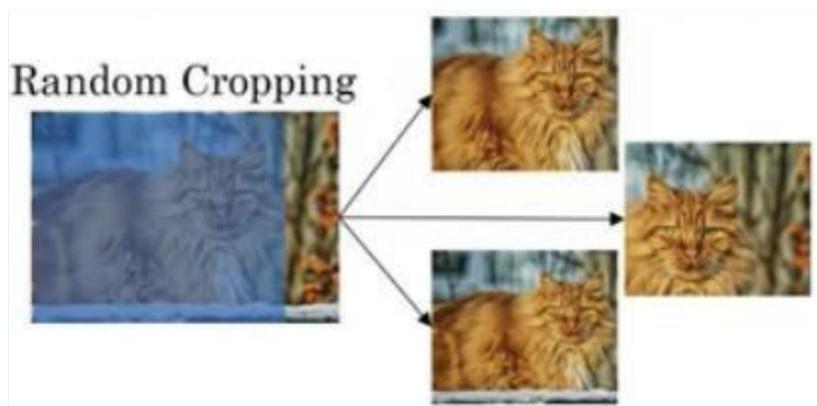


Figure 3.4 : Recadrage [72]

La mise en miroir et le recadrage, sont des techniques utilisées fréquemment. Elles sont néanmoins loin d'être les seules approches [71]. En effet, il existe également d'autres opérations qu'on peut utiliser telles que :

- Le froissement (Shearing)
- L'effacement aléatoire d'une zone de l'image
- La rotation aléatoire qui consiste en une simple rotation de l'image selon un quelconque angle
- Le décalage horizontal qui comble automatiquement le vide créé à droite ou à gauche
- Le décalage vertical qui comble automatiquement le vide créé en haut ou en bas.

Elles sont néanmoins peu utilisées, en pratique dus à leurs complexités.

Le troisième type d'augmentation des données, communément utilisé, est le **décalage des couleurs**, ou **La variation des paramètres de l'image à travers la modification aléatoire de la luminosité, du contraste et/ou de la saturation**.

A partir de l'image originale, on peut rajouter aux canaux R, G, B différentes distorsions (figure 3.5), créant une image distordue pour l'ensemble d'entraînement, où l'étiquette de cette dernière, demeure la même que l'originale. Ceci rendra l'algorithme d'apprentissage, plus robuste aux modifications des couleurs des images [71, 72].

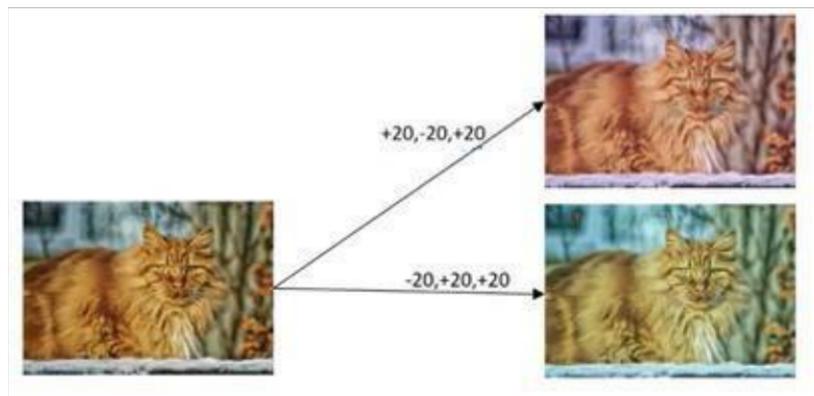


Figure 3.5: Distorsions (décalages de couleurs) [72]

Architectures des réseaux de neurones convolutifs

Depuis ces dernières années, les réseaux de neurones convolutifs dominent les approches de l'apprentissage automatique, pour la reconnaissance visuelle des objets. En effet, leur développement constant durant ces 20 dernières années, a laissé découvrir une multitude de techniques distinctes ; le réseau LeNet contenant 5 couches, les VGG (16-19) et le ResNet (Residual Networks), qui ont dépassé les 100 couches et bien d'autres encore [73, 74].

Modèle VGG

a Un peu d'histoire

Le VGG est une abréviation du « Visual Geometry Group » c'est une architecture de réseau de neurones convolutifs classique. Basé sur une analyse de la façon d'augmenter la profondeur de ces réseaux. Il a été créé par **K. Simonyan et A. Zisserman**, dans le laboratoire universitaire de la géométrie visuelle d'Oxford.

Le modèle a atteint une précision de 92.7% et est devenu célèbre, à l'occasion d'une compétition **ImageNet Large Scale Visual Recognition Challenge (ILSVRC)** en 2014 [75].

Il a marqué une progression par rapport aux modèles précédents (tableau 3.1), en proposant, dans les couches de convolution, des noyaux de convolution de plus petites dimensions (3×3) que ce qui avait été fait jusque-là. Le modèle a été entraîné sur des semaines, en utilisant des cartes graphiques de pointe. Le modèle VGG est donc caractérisé par sa simplicité.

Method	top-1 val. error (%)	top-5 val. error (%)	top-5 test error (%)
VGG (2 nets, multi-crop & dense eval.)	23.7	6.8	6.8
VGG (1 net, multi-crop & dense eval.)	24.4	7.1	7.0
VGG (ILSVRC submission, 7 nets, dense eval.)	24.7	7.5	7.3
GoogLeNet (Szegedy et al., 2014) (1 net)	-	-	7.9
GoogLeNet (Szegedy et al., 2014) (7 nets)	-	-	6.7
MSRA (He et al., 2014) (11 nets)	-	-	8.1
MSRA (He et al., 2014) (1 net)	27.9	9.1	9.1
Clarifai (Russakovsky et al., 2014) (multiple nets)	-	-	11.7
Clarifai (Russakovsky et al., 2014) (1 net)	-	-	12.5
Zeiler & Fergus (Zeiler & Fergus, 2013) (6 nets)	36.0	14.7	14.8
Zeiler & Fergus (Zeiler & Fergus, 2013) (1 net)	37.5	16.0	16.1
OverFeat (Sermanet et al., 2014) (7 nets)	34.0	13.2	13.6
OverFeat (Sermanet et al., 2014) (1 net)	35.7	14.2	-
Krizhevsky et al. (Krizhevsky et al., 2012) (5 nets)	38.1	16.4	16.4
Krizhevsky et al. (Krizhevsky et al., 2012) (1 net)	40.7	18.2	-

Tableau 3.1: Résultats obtenus sur ImageNet [75]

b ***Présentation du modèle VGG***

Selon la taille du noyau de convolution et le nombre de couches de convolution, le modèle Visual geometry group peut être divisé en 6 configurations (ConvNet Configuration) (figure 3.7), A, A-LRN, B, C, D et E. Parmi elles, D et E sont couramment utilisées, respectivement appelés VGG16 [76] et VGG19 [77].

Le modèle A représente le modèle le plus basique, avec 8 couches de base en rouleur et 3 couches entièrement connectées, soit un total de 11 couches. Sur la base de A, une couche convolutive 3X3 est ajoutée respectivement sur la base de 'stage1' et 'stage2', pour un total de 13 couches, créant ainsi le modèle B.

Le modèle C, se compose d'une couche de convolution 1X1, ajoutée sur la base de 'stage3', 'stage4' et 'stage5', sur la base de B, soit donc un total de 16 couches.

Pour le modèle D, une couche convolutive 3X3 sera ajoutée sur la base de 'stage3', 'stage4' et 'stage5', sur la base de B pour un total de 16 couches, formant de ce fait, le réseau VGG16.

Sur la base de D, une couche convolutive 3X3 est ajoutée sur la base de 'stage3', 'stage4' et 'stage5', soit un total de 19 couches, formant le modèle E ou plus communément appelé, le VGG19.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Figure 3.6 : Six configurations structurelles de VGG [75]

La partie verte sur la figure 3.6, indique la structure du VGG16. Nous constatons qu'il se compose de :

- 13 couches convolutives (convolutional layers), représentées par conv3-XXX.
- 3 couches entièrement connectées (fully connected layers), représentées par FC-XXXX.
- 5 couches de mise en commun (couches de pooling), représentées par Maxpool. Parmi elles, existent des couches de pondération qui sont en réalité, une couche convolutive et une couche entièrement connectée, qui possèdent des coefficients de pondération. Le nombre total de couches, est donc de $13 + 3 = 16$, soit 16 dans VGG16.

c Caractéristiques structurelles du VGG

Entre le VGG16 (figures 3.7 et 3.8) et le VGG19 (figure 3.9), les deux architectures (figure 3.10) très proches, respectent la même logique, sauf que le VGG19 présente un plus grand nombre de couches de convolution. Le modèle ne demande qu'un prétraitement spécifique, qui consiste à soustraire la valeur RGB moyenne, calculée sur l'ensemble d'apprentissage, de chaque pixel.

L'entrée de la première **couche de convolution** est une image RGB de taille 224x224. Pour toutes les couches de convolution, le noyau de convolution est de taille 3x3 : la plus petite dimension, pour capturer les notions de haut, bas, gauche/droite et centre. C'était une spécificité du modèle au moment de sa publication [75].

Jusqu'au VGG16, beaucoup de modèles s'orientaient vers des noyaux de convolution de plus grande dimension (de taille 11 ou bien de taille 5 par exemple).

Ces couches de convolution s'accompagnent de **couche de Max-Pooling**, chacune de taille 2x2, pour réduire la taille des filtres, au cours de l'apprentissage.

En sortie des couches de convolution et de pooling, le modèle VGG, contient 3 couches de neurones **Fully-Connected**. Les deux premières sont composées de 4096 neurones et la dernière de 1000 neurones, avec une fonction d'activation softmax pour déterminer la classe de l'image [75].

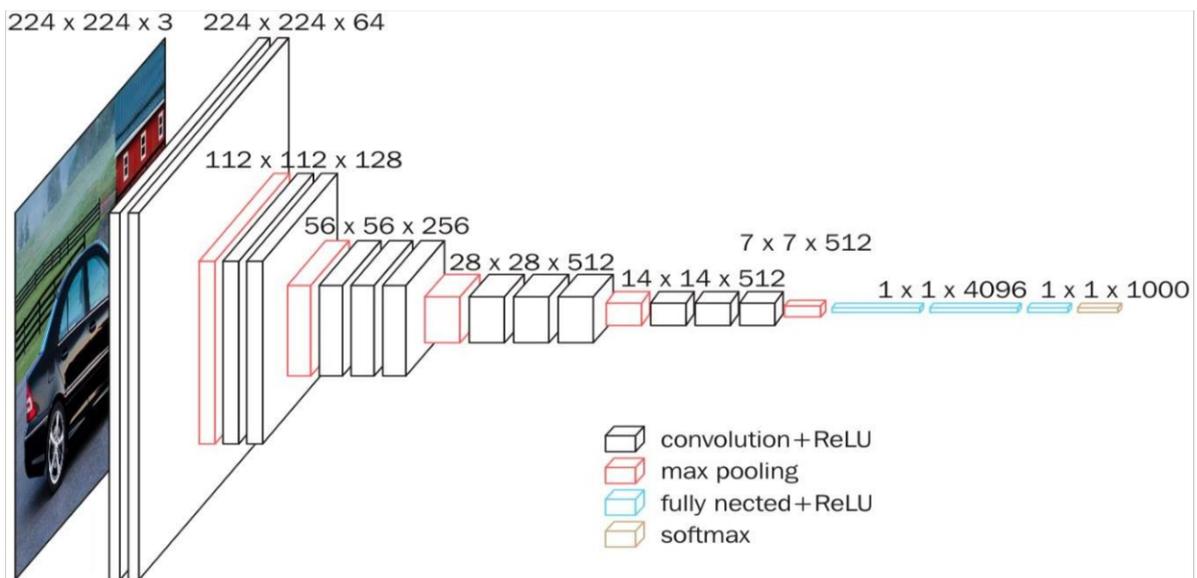


Figure 3.7 : Structure du modèle VGG16 [76]

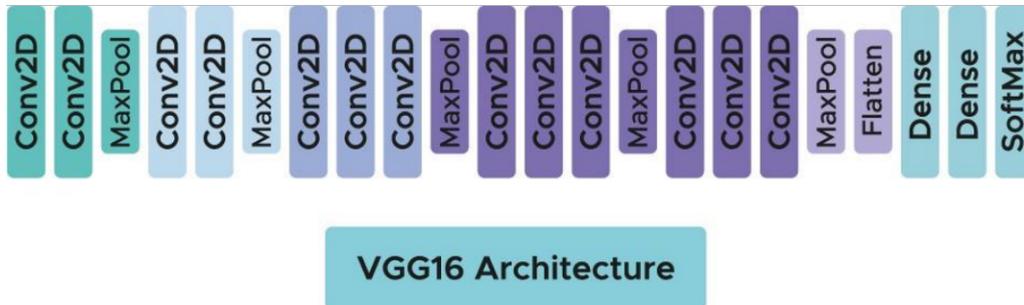


Figure 3.8: Architecture du modèle VGG 16 [76]

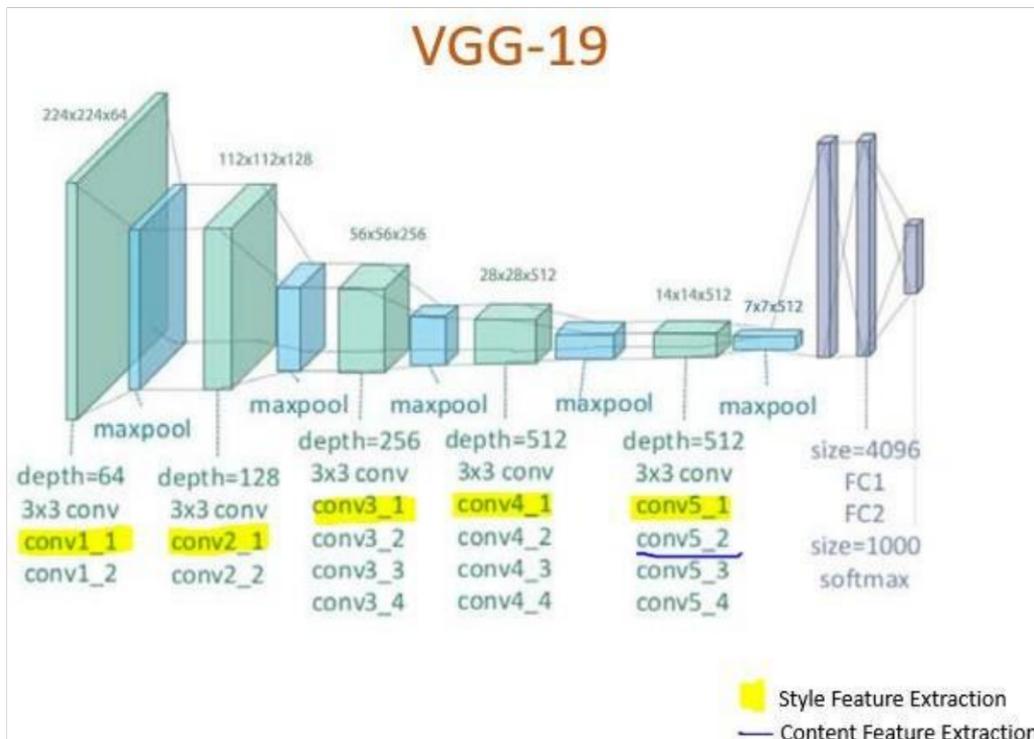


Figure 3.9: Architecture de VGG 19 [77]

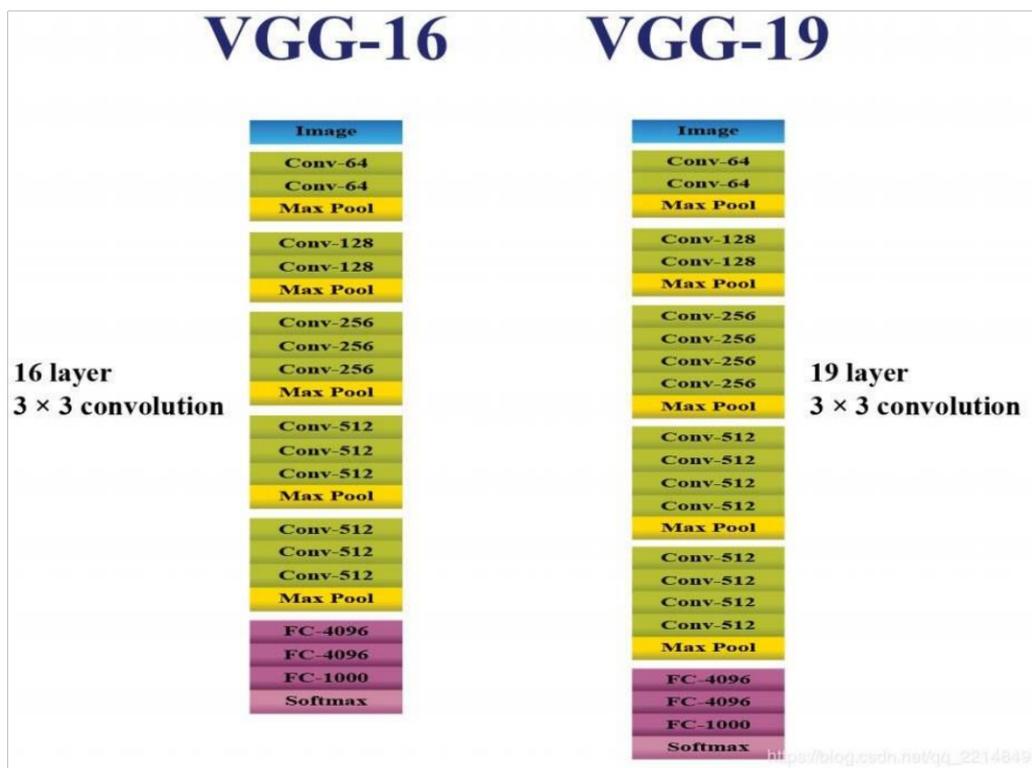


Figure 3.10 : Couches détaillées du VGG 16 et VGG 19 [75]

Modèle Inception/GoogLeNet

En imagerie médicale, l'architecture Inception est souvent utilisée pour la classification des anomalies, notamment pour définir le stade de la maladie. Il porte le nom d'un autre modèle nommé « Network-In-Network » [78]. L'idée clé, était de se rendre compte que les "filtres" convolutifs conventionnels ne peuvent apprendre que les fonctions linéaires, de leurs entrées. Pourquoi ne pas augmenter leurs capacités d'apprentissage et leur pouvoir d'abstraction en ayant des "filtres" plus complexes ?

a Un peu d'histoire

En 2014, GoogLeNet fut proclamé le gagnant de l'ILSVRC (ImageNet Large Scale Visual Recognition Competition), un concours de classification d'images. Il présenta une amélioration significative (figures 3.11 et 3.12) par rapport au ZFNet et AlexNet et, a obtenu un taux d'erreur plus faible que le VGGNet.

Le nom GoogLeNet tient son nom, bien évidemment de Google, ainsi que LeNet en hommage au professeur Yan LeCun's LeNet. Il est également appelé Inception V1, qui a été développé plus tard en Inception v2, Inception v3, Inception v4 [78].

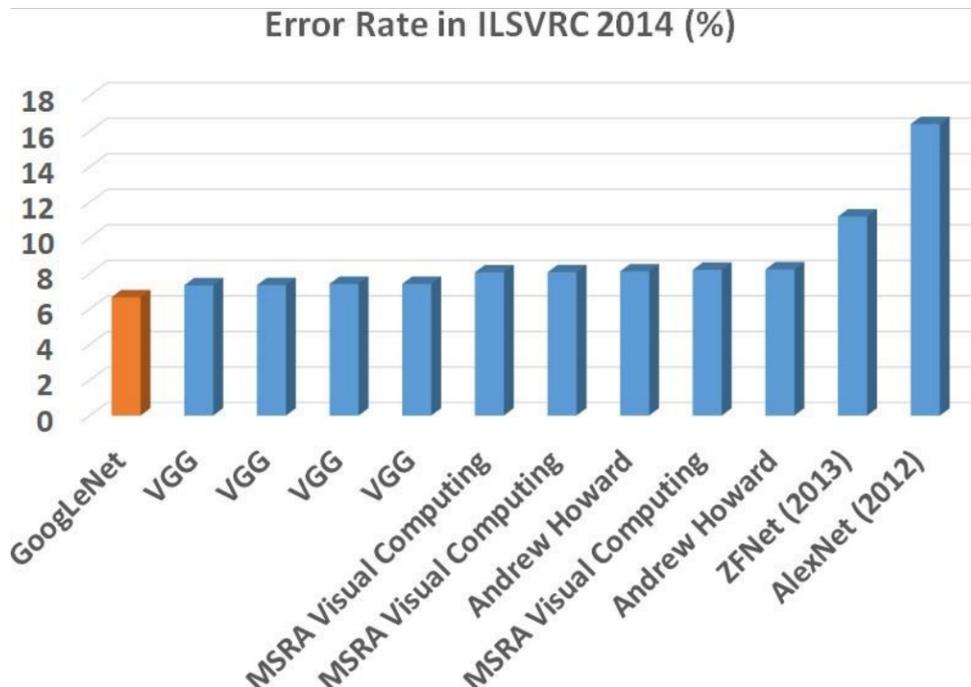


Figure 3.11 : Taux d'erreur dans l'ILSVRC 2014 [78]

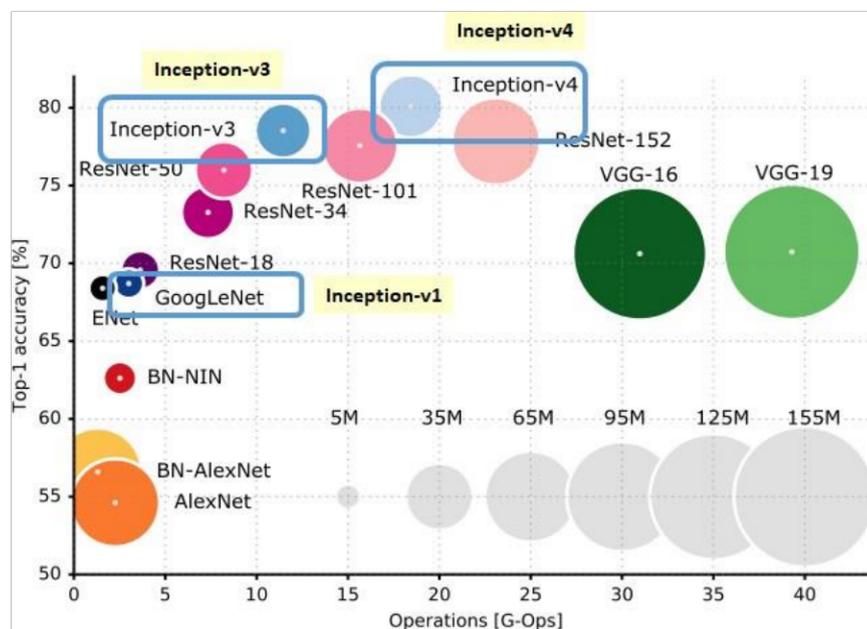


Figure 3.12: Précision Top-1 par rapport au nombre d'opérations [78]

b Architecture du modèle Inception

L'idée principale de la structure du modèle Inception est de considérer l'approximation d'un modèle local optimal et le couvrir par des composants denses facilement disponibles [78, 79, 80].

Pour capturer la variabilité du jeu de données tout en évitant d'exploser la consommation de ressources, l'architecture Inception (figures 3.13 et 3.14) repose sur l'utilisation de blocs de traitement.

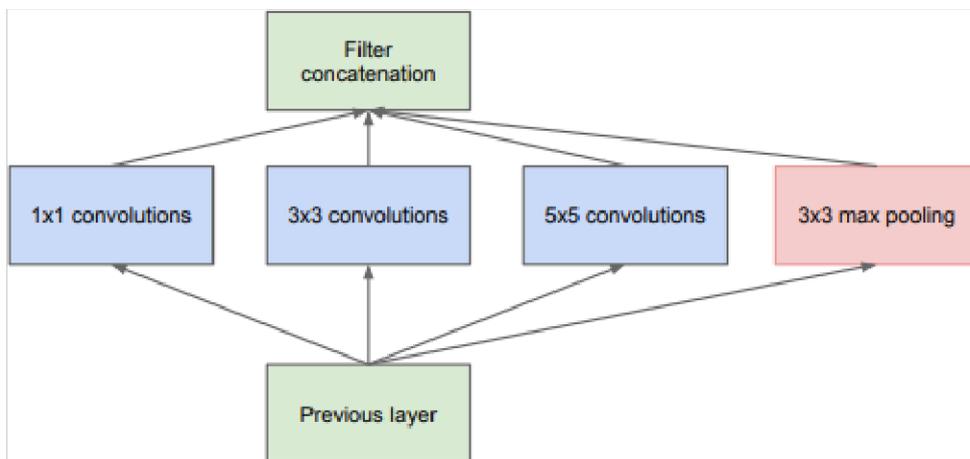


Figure 3.13: Modèle Inception (version naïve) [78]

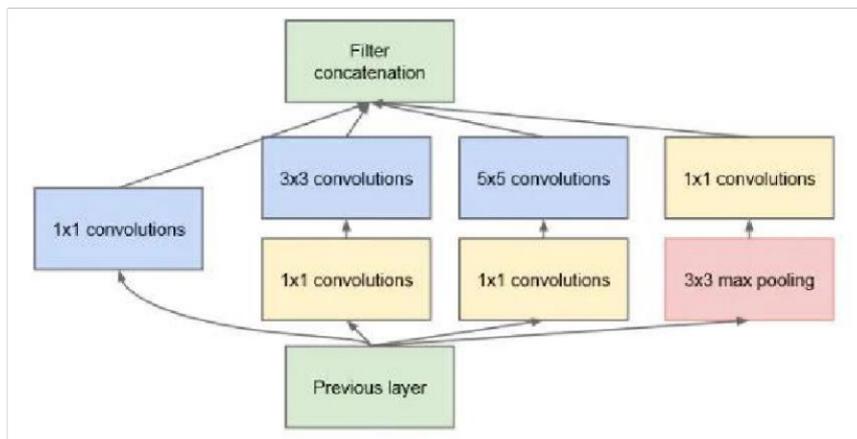


Figure 3.14 : Modèle Inception avec dimension réduite [78]

c Inception v1

GoogLeNet (tableau 3.2) est le lancement de l'Inception. L'entrée passe par 1×1 , 3×3 et 5×5 conv, simultanément, ainsi que par une mise en commun maximale, et concaténée en sortie. Ainsi, nous n'avons pas besoin de penser, à la taille du filtre à utiliser pour chaque couche [78].

Ce réseau est formé avec différentes méthodes d'échantillonnage de patches d'images, il a été conçu, en gardant à l'esprit, l'efficacité et la précision de l'informatique, de sorte que l'inférence puisse être exécutée sur des appareils individuels, y compris ceux dont les ressources informatiques sont limitées.

type	patch size/ stride	output size	depth	#1×1	#3×3 reduce	#3×3	#5×5 reduce	#5×5	pool proj	params	ops
convolution	7×7/2	112×112×64	1							2.7K	34M
max pool	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
max pool	3×3/2	28×28×192	0								
inception (3a)		28×28×256	2	64	96	128	16	32	32	159K	128M
inception (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
max pool	3×3/2	14×14×480	0								
inception (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
inception (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
inception (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
inception (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
inception (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
max pool	3×3/2	7×7×832	0								
inception (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
inception (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
avg pool	7×7/1	1×1×1024	0								
dropout (40%)		1×1×1024	0								
linear		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								

Tableau 3.2 : GoogLeNet l'incarnation de l'architecture Inception [78]

d Inception-v2/BN-Inception

Cette approche (figures 3.15 et 3.16) introduit une technique d'apprentissage en profondeur très essentielle appelée normalisation par lots (*Batch Normalization*) [79, 80].

BN-Inception (figure 3.17) est utilisé pour normaliser la distribution des valeurs avant de passer à la couche suivante. Avec BN, une précision plus élevée et une vitesse d'entraînement plus rapide peuvent être obtenues.

La fonction ReLU [81] est utilisée comme fonction d'activation, pour résoudre le problème de saturation et les gradients de disparition, qui en résultent. Mais cela rend également la sortie plus irrégulière.

Il est avantageux que la distribution de X , reste fixe dans le temps car un petit changement, sera amplifié lorsque le réseau ira plus loin. Un taux d'apprentissage plus élevé, peut être utilisé. De plus, 5×5 conv a été remplacée par deux 3×3 convs, pour la réduction des paramètres tout en maintenant la taille du champ réceptif [80].

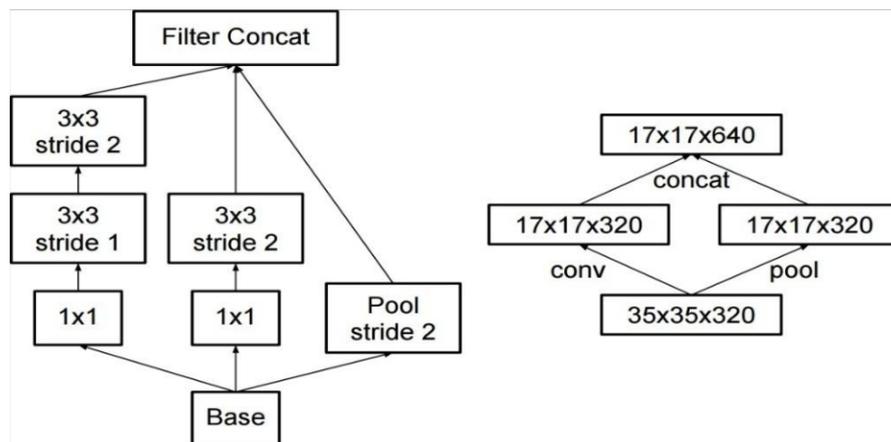


Figure 3.15 : Modèle Inception v2 [80]

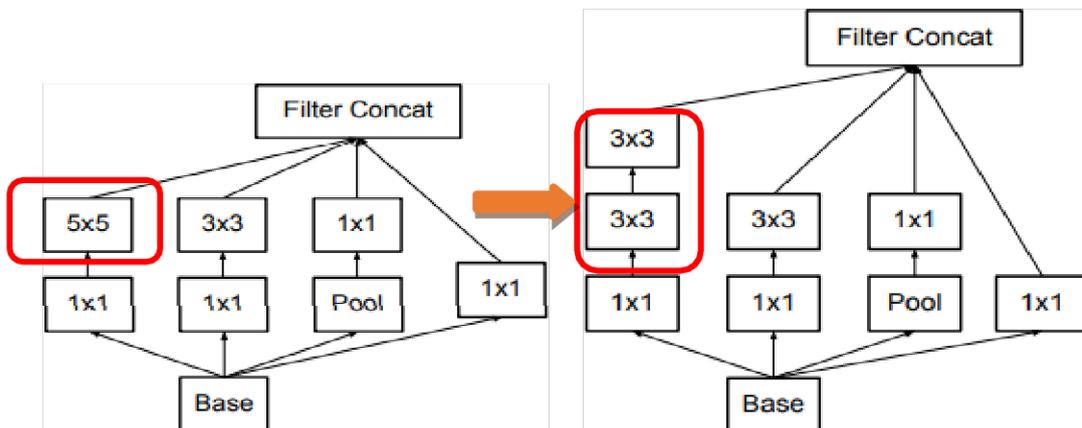


Figure 3.16 : Réseau Inception avec remplacement de conv 5×5 par deux conv 3×3 [80]

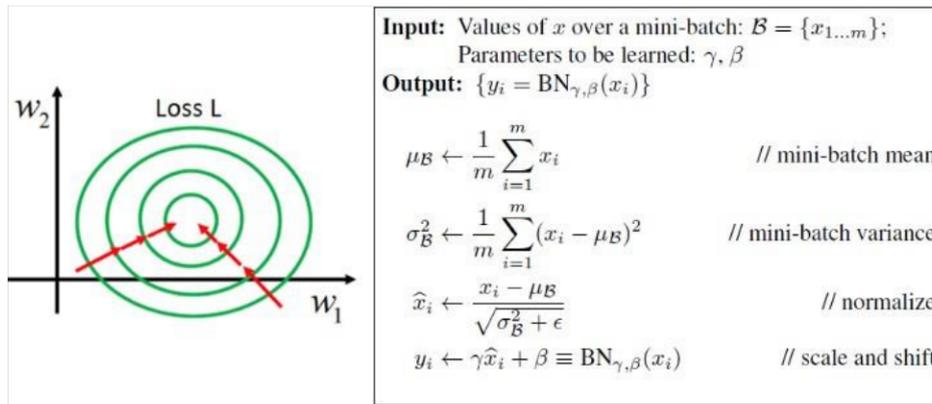


Figure 3.17 : Normalisation par lots (BN) [80]

e Inception v3

Inception V3 est la 3ème version, d'une série d'architectures convolutives d'apprentissage profond. Le modèle a été formé à l'aide d'un ensemble de données, de 1 000 classes. Le réseau fut créé pour l'ImageNet Large Visual Recognition Challenge, où il a été le premier finaliste en 2015 [82, 83].

Plus tard il a été affiné par l'idée de la factorisation, qui a été introduite dans la couche de convolution comme indiqué par la figure 3.18, pour réduire davantage la dimensionnalité, afin de réduire le problème du sur-ajustement (overfitting). Dans le cas de l'architecture de la figure 3.19, la couche inférieure du réseau, se compose d'une conv 3x1 avec 3 unités de sortie. Par exemple :

- En utilisant un filtre 3×3 , le nombre de paramètres = $3 \times 3 = 9$.
- En utilisant des filtres 3×1 et 1×3 , le nombre de paramètres = $3 \times 1 + 1 \times 3 = 6$.

Le nombre de paramètres est ainsi réduit de 33%.

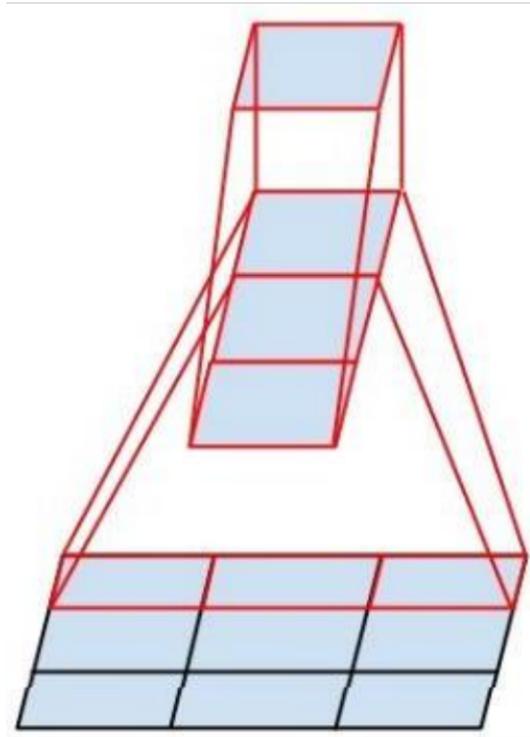


Figure 3.18 : Mini-réseau remplaçant une convolution de 3x3 [82]

Après la factorisation (figure 3.19), le nombre de paramètres est réduit pour l'ensemble du réseau, il est donc moins susceptible de subir un sur-ajustement. Le réseau peut être donc, approfondi. De ce fait, avec 42 couches de profondeurs, une diminution de paramètres et une complexité similaire au VGGNet, le modèle Inception V3 a été réalisé.

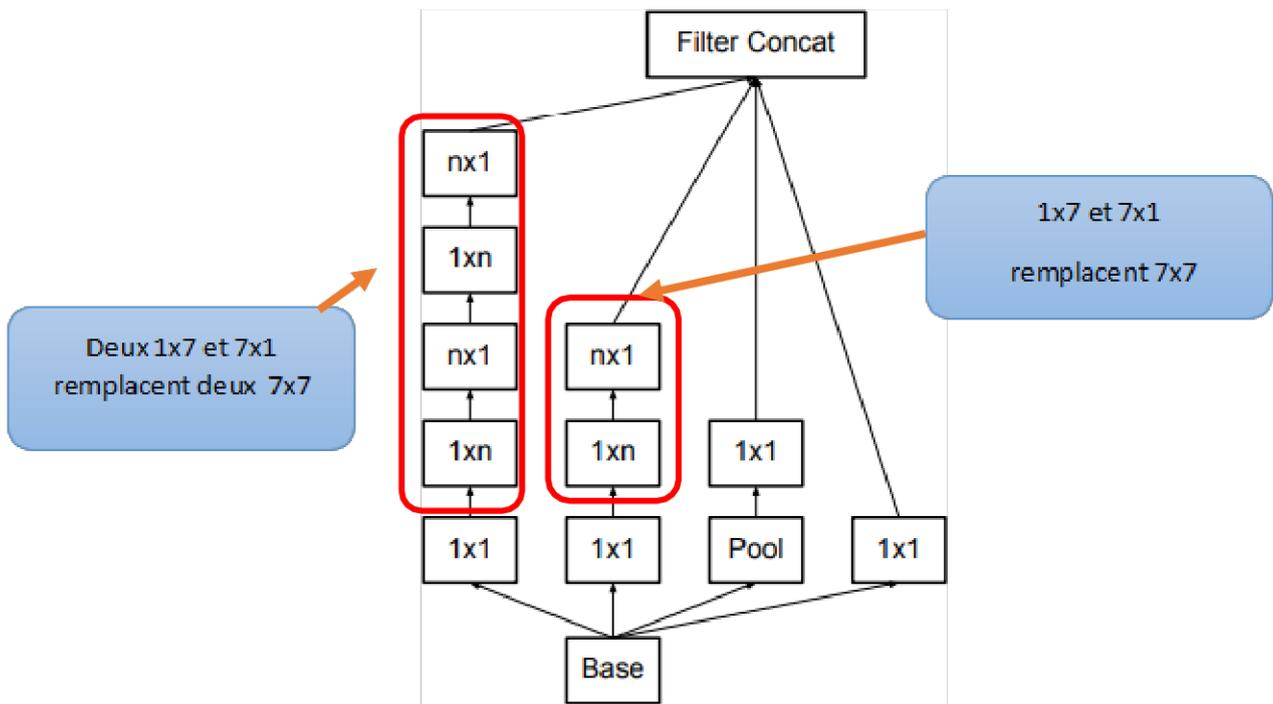


Figure 3.19 : Inception après la factorisation des conv $n \times n$ [82]

Dans l'architecture proposée $n=7$ pour une grille 17×17 . C'est cette même architecture (figure 3.20), que notre travail adopte.

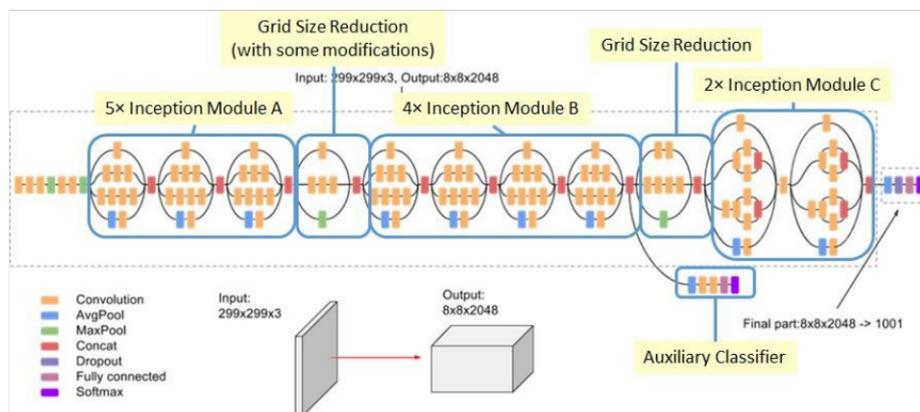


Figure 3.20 : Architecture de l'Inception-v3 (BN et Relu sont utilisés après Conv) [83]

f Inception v4

Inception V4 [84] est l'un des derniers modèles dérivés de l'architecture GoogLeNet. Il est simple, plus uniforme et plus de modules de démarrage que Inception-v3, il obtient de meilleurs résultats en classification d'images médicales [56].

Il s'agit d'une pure variante Inception, sans aucune connexion résiduelle. Il peut être formé sans partitionner les réplicas, avec une optimisation de la mémoire pour la rétro-propagation. Dans le schéma de la structure suivant, chaque module de démarrage a une couche convolutive 1x1 sans couche active pour augmenter le nombre de canaux afin de compenser la réduction de dimensionnalité causée par le module de démarrage.

L'architecture de base (cf. figure 3.21), peut atteindre des performances extrêmement élevées à un faible coût de calcul. L'introduction des connexions restantes dans l'architecture classique du réseau a obtenu d'excellents résultats jugés similaires à la dernière version du réseau Inception v3 à l'époque.

Il a été également confirmé que la combinaison des liens restants, peut accélérer considérablement, la formation Inception formant de ce fait, le modèle Inception-v4 entier.

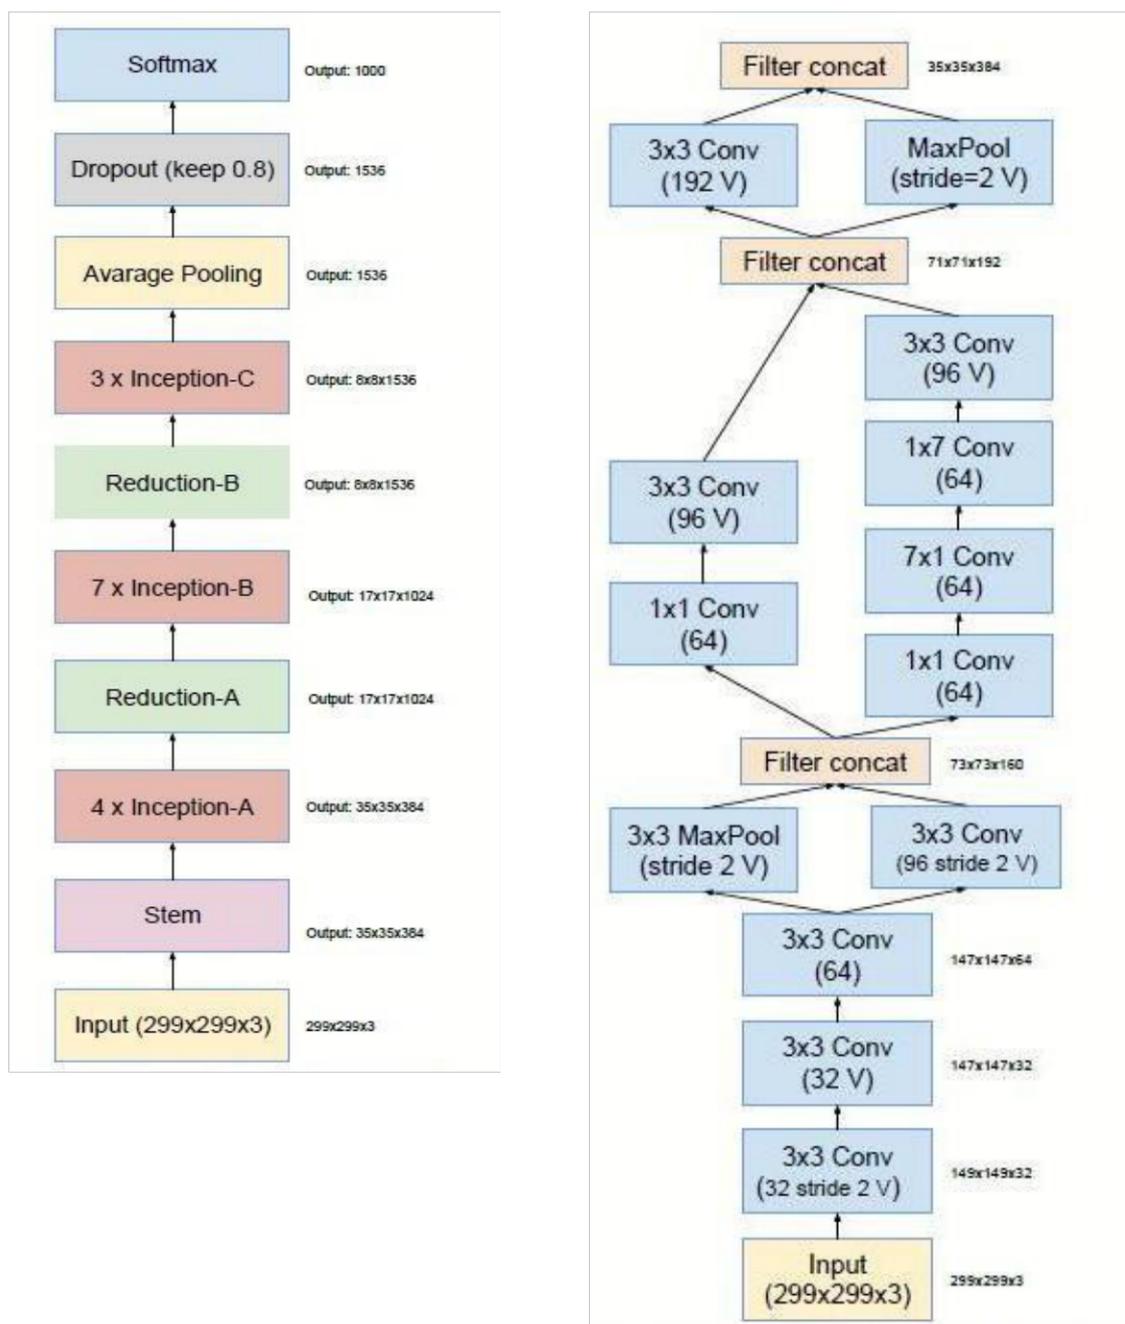


Figure 3.21 : Architecture générale de l'Inception-V4 (à gauche)
Sur la droite : la composition détaillée de la tige [84]

g Comparaison entre les différentes versions d'Inception

Le tableau 3.3 démontre les différences présentes, entre les 3 modèles d'Inception V1, V2 et V3 :

Inception V1	Inception V2	Inception V3
Augmente le nombre d'unités à chaque étape et protège le grand nombre de filtres d'entrée du dernier étage vers les couches suivantes	Augmente le taux d'apprentissage, supprime le dropout et la normalisation de la réponse locale, mélange les exemples d'entraînement de manière plus approfondie et réduit la régularisation du poids L2 et les distorsions photométriques	Entraîné et formé plus rapidement en comparaison avec les autres modèles d'Inception et aux autres méthodes
Taux d'erreur = 6.67%	Taux d'erreur = 4.82%	Taux d'erreur = 3.5%

Tableau 3.3 : Comparaison entre Inception V1, Inception v2 et Inception v3 [83]

La figure 3.22 présente les résultats de la compétition de l'ILSVRC en 2015 [83], cette dernière illustre clairement, qu'avec le Single-Crop Single-Model, Inception-V4 et Inception-ResNet ont obtenu les meilleures performances avec des résultats similaires.

Network	Top-1 Error	Top-5 Error
BN-Inception (Ioffe and Szegedy 2015)	25.2%	7.8%
Inception-v3 (Szegedy et al. 2015b)	21.2%	5.6%
Inception-ResNet-v1	21.3%	5.5%
Inception-v4	20.0%	5.0%
Inception-ResNet-v2	19.9%	4.9%

Figure 3.22 : Résultats de la compétition de l'ILSVRC 2015 [83]

Modèle ResNet 50

a Introduction

ResNet, abréviation de Residual Networks, est un réseau de neurones classique utilisé comme épine dorsale pour de nombreuses tâches de la vision par ordinateur. Ce modèle a remporté le défi ImageNet en 2015 [84]. La percée fondamentale avec ResNet, était qu'il nous a permis de former avec succès des réseaux de neurones extrêmement profonds, avec plus de 150 couches.

Avant ResNet, la formation de réseaux de neurones très profonds était difficile en raison du problème des gradients de disparition. Le réseau a une taille d'entrée d'image de 224 par 224 [85, 86].

Les réseaux de neurones résiduels, utilisent des connexions sautées ou des raccourcis pour sauter par-dessus certaines couches.

Les avantages de ces réseaux, résident en leur capacité à réduire la fuite du gradient, dans les couches inférieures du réseau et, la possibilité de leur mise à l'échelle en profondeur. Cette dernière permet l'ajustement de l'architecture, à la tâche de classification à accomplir. Bien que coûteux en ressources de calcul, ils obtiennent de très bonnes performances en classification, sur tous les niveaux de détails de l'image, même les plus fins [84].

b Architecture du ResNet50

Le problème de la formation de réseaux très profonds, a été résolu avec l'introduction de ces blocs résiduels et le modèle ResNet est constitué de ces blocs (figure 3.23). Dans la figure ci-dessous, la toute première chose que nous pouvons remarquer, est qu'il existe une connexion directe qui ignore certaines couches du modèle. Cette connexion est appelée « connexion à ignorer » et constitue le cœur des blocs résiduels. La sortie n'est pas la même en raison de ce saut de connexion. Sans la connexion de saut, l'entrée 'X est multipliée par les poids de la couche suivie de l'ajout d'un terme de biais.

Grâce à la fonction d'activation, f la sortie est obtenue sous la forme $H(x)$ (3.1).

$$H(x) = f (w x + b) \text{ ou } H(x) = f (x) \quad 3.1$$

Avec l'introduction d'une nouvelle technique de connexion par saut, la sortie $H(x)$ est changée en $H(x)=f(x)+x$

Cependant, la dimension de l'entrée peut être différente de celle de la sortie, ce qui peut arriver avec une couche convolutive ou des couches de mise en commun. Par conséquent, ce problème peut être traité avec ces deux approches :

- Zéro rembourré avec la connexion de saut pour augmenter ses dimensions.
- Des couches convolutives 1×1 sont ajoutées à l'entrée pour correspondre aux dimensions.

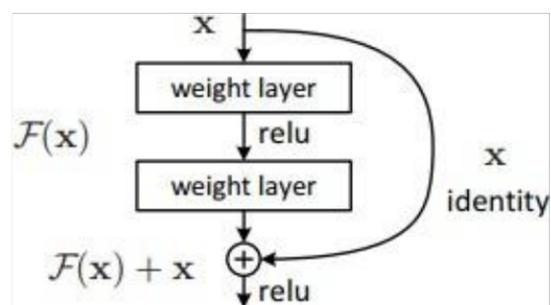


Figure 3.23 : Bloc résiduel [86]

Le modèle ResNet-50 se compose de 5 étapes, chacune d'elles, avec une convolution et un bloc d'identité (figure 3.24). Chaque bloc de convolution possède 3 couches de convolution, tout comme le bloc d'identité, qui se compose également de 3 couches de convolution. Le ResNet-50 possède plus de 23 millions de paramètres, pouvant être entraînés [86, 87].

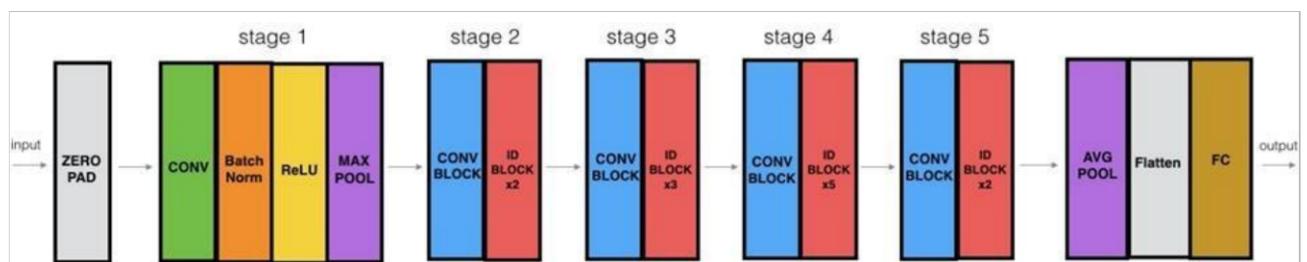


Figure 3.24 : Architecture du ResNet50 [87]

Apprentissage par Transfert

Dans de nombreuses applications du monde réel, il est coûteux, voire même impossible, de récupérer les données de formation nécessaires et, de reconstruire les modèles. Il serait préférable donc, de réduire le besoin et l'effort de recollecter les données d'entraînement. Dans de tels cas, le plus judicieux serait d'employer un apprentissage par transfert [88].

L'apprentissage par transfert ou '*Transfer Learning*', est une technique d'apprentissage automatique, dans laquelle un modèle formé sur une tâche, est réutilisé sur une deuxième tâche connexe. Il représente une optimisation qui permet une progression rapide ou une amélioration des performances, lors de la modélisation de la deuxième tâche [89].

Dans l'apprentissage par transfert, nous entraînons d'abord un réseau de base sur un jeu de données et une tâche de base, puis nous réutilisons les fonctionnalités apprises, ou les transférons, vers un deuxième réseau cible pour être formé sur un jeu de données et une tâche cible. Ce processus aura tendance à fonctionner si les fonctionnalités sont générales, c'est-à-dire adaptées aux tâches de base et cibles, au lieu d'être spécifiques à la tâche de base.

Les modèles utilisés dans ce domaine nécessitent souvent, un large temps de calcul et énormément de ressources. En utilisant, néanmoins, des modèles pré-entraînés comme point de départ, l'apprentissage par transfert permet le développement rapide de modèles performants et de solutions efficaces, à des problèmes complexes de la vision par ordinateur, ou du traitement du langage naturel [89].

De ce fait, plutôt que d'initialiser les paramètres d'un réseau aléatoirement, ils sont initialisés à partir des valeurs finales des paramètres de cet algorithme tiers. L'entraînement est fait à partir du jeu de données spécifique au projet. L'un des modèles les plus connus pouvant être utilisés pour l'apprentissage par transfert, est Inception V3.

Basé sur la définition du '*transfer learning*', il est possible de le catégoriser (figure 3.25) sous 3 sous-ensembles : l'apprentissage par transfert inductif, transductif et non-supervisé (tableau 3.4), en fonction des nombreuses situations entre la source et la cible, les domaines et les tâches [88].

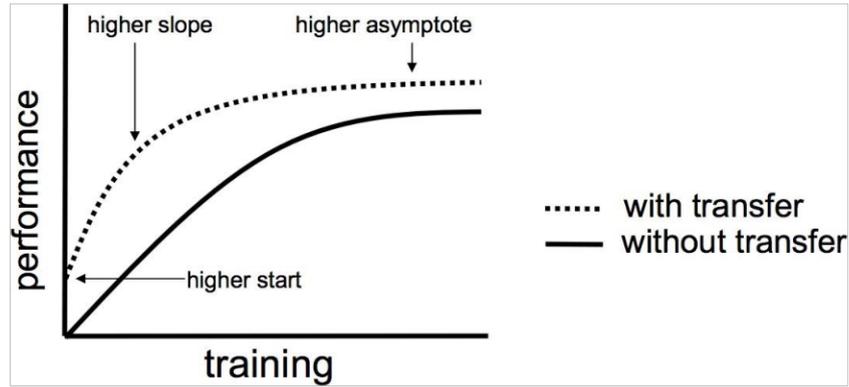


Figure 3.25: Techniques d'amélioration de l'apprentissage [89]

Paramètres du Transfer Learning	Domaines connexes	Etiquettes du domaine source	Etiquettes du domaine cible	Tâches
Transfer Learning Inductif	Multi-task Learning	Disponible	Disponible	Régression, Classification
	Self-taught Learning	Indisponible	Disponible	Régression, Classification
Transfer Learning Transductif	Domain Adaptation, Sample Selection Bias, Co-variante Shift	Disponible	Indisponible	Régression, Classification
Transfer Learning Non-supervisé		Indisponible	Indisponible	Regroupement, Réduction de la dimensionnalité

Tableau 3.4 : Différents paramètres de l'apprentissage par transfert [88]

Le Transfer Learning permet non-seulement d'accélérer l'entraînement du réseau, mais également d'éviter le sur-apprentissage (overfitting). Lorsque la collection d'images en entrée est petite, il est judicieux d'éviter l'entraînement du réseau de neurones en partant de zéro, le nombre de paramètres étant largement supérieur au nombre d'images, le risque de sur-apprentissage est énorme [90].

L'utilisation des méthodes de 'Transfer Learning' en Deep Learning, consiste principalement à exploiter des réseaux de neurones pré-entraînés [90]. En général, ces modèles correspondent à des algorithmes performants développés et entraînés sur de larges bases de données. Il existe deux types de stratégies :

Stratégie 1 : extraction des caractéristiques

Cette stratégie consiste à réutiliser un réseau pré-entraîné sans sa couche finale. Ce nouveau réseau fonctionne alors, comme un extracteur de caractéristiques fixes, pour la réalisation d'autres tâches. De ce fait, la couche FC est retirée alors que, les autres paramètres sont fixés.

Ce réseau tronqué, va ainsi calculer la représentation de chaque image en entrée, à partir des caractéristiques déjà apprises, lors du pré-entraînement. Un classifieur sera alors entraîné, initialisé aléatoirement, sur ces représentations pour résoudre le nouveau problème [90, 91].

La figure 3.26 indique les performances du deep learning, dans la reconnaissance de formes et la détection d'objets. Ces modèles sont spécifiquement entraînés sur la tâche (vert), par rapport aux modèles pré-entraînés (rouge, rose)

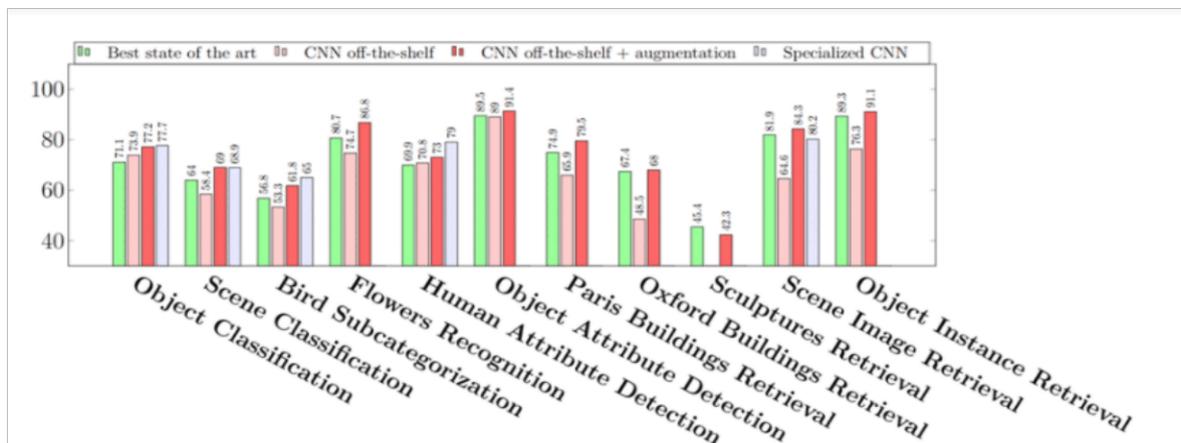


Figure 3.26 : Performances des modèles du Deep Learning [90]

Ajustement de modèles pré-entraîné (Fine-tuning)

Cette technique a également pour objectif, de tirer profit des apprentissages antérieurs d'un modèle pré-entraîné, sur un jeu de données de taille importante. Les modèles avec un très grand nombre de paramètres, comme les réseaux de neurones profonds, doivent être entraînés sur des jeux de données de taille, tout aussi importante, pour réduire le risque de sur-apprentissage (figure 3.27).

A partir d'un modèle pré-entraîné sur un jeu de données de n classes, sa couche de classification finale est modifiée pour correspondre à la tâche à effectuer, soit la classification de m classes (e.g. $m < n$, avec le jeu de données spécifique à la tâche).

Désormais, le modèle pré-entraîné possède maintenant une couche de classification finale de m sorties. Les paramètres des couches d'extraction des caractéristiques du modèle sont exclus de la phase de rétro-propagation (i.e. figés), afin de conserver les valeurs estimées lors du pré-entraînement, avec un jeu de données de taille plus importante (ex : ImageNet). Seuls les paramètres des couches de la classification du modèle, seront entraînés sur le jeu de données spécifique [91].

L'ajustement 'fine-tuning', permet de réduire le temps d'apprentissage et le risque de sur-apprentissage du modèle inhérent, à un jeu de données de taille inférieure, au nombre de paramètres du modèle [91].

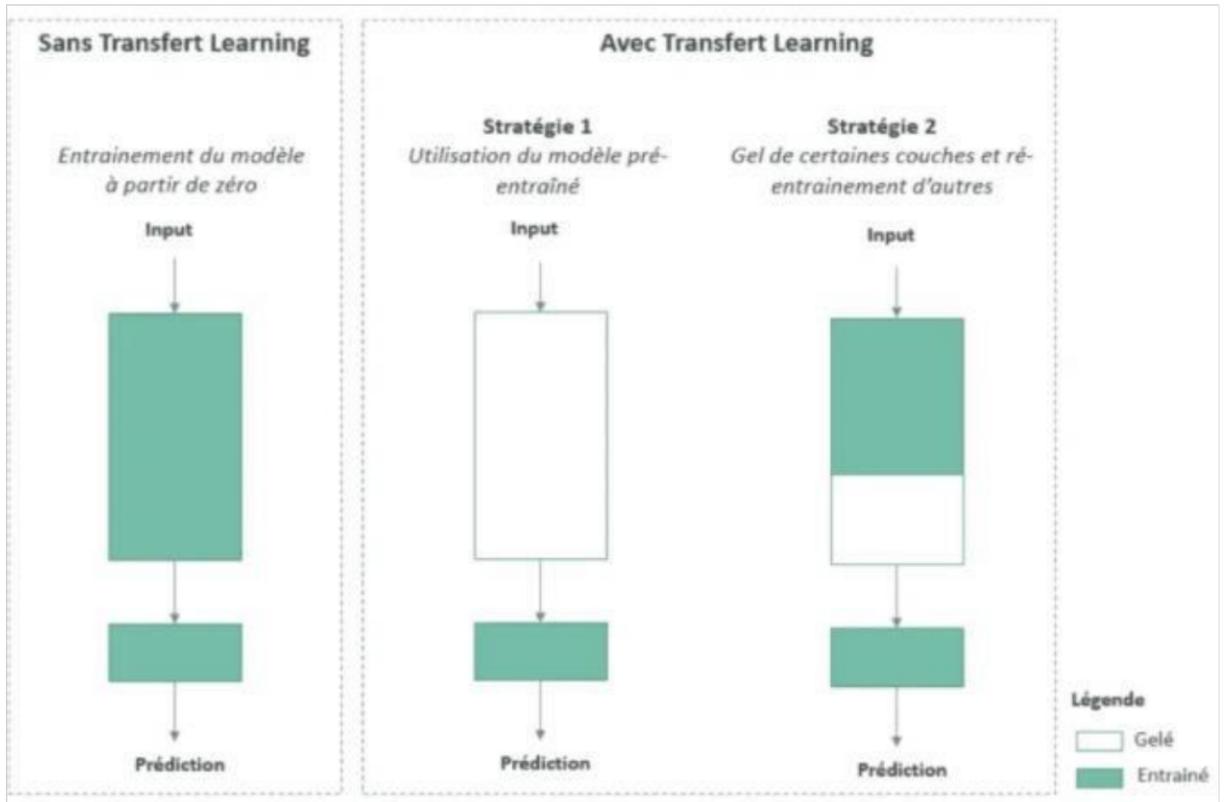


Figure 3.27 : Approche du Transfer Learning en Deep Learning [89]

Cette technique regroupe deux stratégies :

- **Un fine-tuning total** : où la dernière couche fully-connected du réseau pré-entraîné, est remplacée par un classifieur adapté au nouveau problème (SVM, régression logistique...) et initialisé de manière aléatoire. Toutes les couches seront ensuite entraînées, sur les nouvelles images.
- **Un fine-tuning partiel** : cette technique assemble le fine-tuning total d'un côté et l'extracteur des caractéristiques d'un autre. La dernière couche fully-connected, est remplacée par le nouveau classifieur initialisé aléatoirement et les paramètres de certaines couches du réseau pré-entraîné, sont fixés. Ainsi, en plus du classifieur, les couches non-fixées, seront entraînées sur les nouvelles images, qui correspondent en général aux plus hautes du réseau [91].

Conclusion

Ce chapitre a introduit l'étude conceptuelle de notre approche, pour la réalisation d'un système de détection des différentes pathologies mammaires. Il a abordé, les trois architectures employées pour ce projet de détection et de classification d'images ultrasonores, soient : le VGG16, l'Inception-V3 ainsi que le ResNet suivant l'apprentissage par transfert.

Le chapitre suivant, mettra en œuvre les architectures citées précédemment, afin de les tester lors de la classification des pathologies. Une comparaison entre les différents modèles obtenus, suivant les métriques évaluées sera effectuée, révélant ainsi les performances du système produit.

Chapitre 4

Mise en œuvre de 'BCNNV2' et résultats

Chapitre 4 Mise en œuvre de 'BCNNV2' et résultats

Introduction

Dédié à la réalisation et la conception de notre système d'analyse d'images échographiques mammaires, ce projet de fin d'étude, nous permettra de détecter et de classer les lésions du sein, suivant l'utilisation des techniques.

Ce chapitre introduira, en premier lieu, l'environnement du travail, suivra ensuite, l'implémentation du système adopté, ainsi que les résultats obtenus.

Une étude comparative entre les différents modèles utilisés est effectuée. Nous clôturerons ce travail, par un bilan général sur le projet réalisé.

Environnement de travail

Le système 'BCNNV2' adopte un environnement de travail, spécifique aux techniques de l'apprentissage profond. Nous présentons à cet effet, tous les outils utilisés pour la réalisation de cette étude.

Hardware

Notre projet a été réalisé grâce un ordinateur personnel, ayant les caractéristiques suivantes :

- Marque du PC : HP Pavillon 15A
- Processeur : Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz 2.70 GHz
- Carte Graphique : Intel HD Graphics 620 (HP)
- Ram : 4,00 Go
- Storage : 119GB SAMSUNG MZNTY128HDHP-000H1 (SATA (SSD))

Software

L'implémentation du système 'BCNNV2', a été effectuée sous le système d'exploitation « Windows10 ». Les codes ont été développés avec le langage python, sous l'environnement Anaconda grâce à diverses bibliothèques, 'open source'.

a Langage Python

Employé surtout en machine learning et en data science, le langage python [92], est un langage de programmation open source multiplateformes, orienté objet. Sa simplicité et ses bibliothèques spécialisées, ont permis son utilisation dans de nombreux domaines, tels que, l'analyse de données, ou bien même, la gestion d'infrastructures. Il est principalement utilisé, l'automatisation de tâches aussi simples que fastidieuses.

Grâce à ses nombreuses bibliothèques telles que Panda, Numpy, Scipy, Matplotlib, Scikit-Learn ou encore TensorFlow [93], Python a fortement contribué à l'essor du big data.

Les principaux avantages du langage Python sont :

- Simple, lisible et facile à appréhender ;
- Libre et open source ;
- Extensible et intégrable à d'autres langages.

b Anaconda

Anaconda représente une plateforme de gestion de l'environnement des langages de programmation, Python et R. C'est la plateforme la plus connue et la plus utilisée, en Data Science. La plateforme anaconda, est utilisée pour le développement d'applications dédiées à la science des données et à l'apprentissage automatique (traitement de données, à grande échelles, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement. C'est une distribution libre, qui contient non seulement les environnements Python et R, mais aussi toutes les bibliothèques essentielles pour pouvoir faire de la Data Science (par exemple pour Python : NumPy, Pandas, Matplotlib, pour ne citer qu'elles). Très simple à installer, elle est fonctionnelle sur Windows, MacOS et Linux et possède une large communauté d'utilisateurs, ainsi qu'une documentation très complète en anglais [94].

c Anaconda Navigator

Anaconda Navigator [94], est une interface graphique (GUI) incluse dans la distribution Anaconda. Cette interface (figure 4.1), facilite le lancement d'applications et la gestion des packages conda, des environnements et des canaux sans utiliser la moindre ligne de commande [94].

Le Navigateur peut également accéder à des bibliothèques présentes sur le Cloud Anaconda, ou dans un répertoire Anaconda local, afin de les installer dans un environnement, les exécuter et les mettre à jour. Anaconda Navigator est disponible pour Windows, macOS et Linux.

Les applications disponibles par défaut dans le navigateur sont :

- JupyterLab
- Jupyter Notebook
- Spyder
- PyCharm
- VSCode
- Glueviz
- Orange 3 App
- RStudio
- Anaconda Prompt (Windows only)
- Anaconda PowerShell (Windows only).

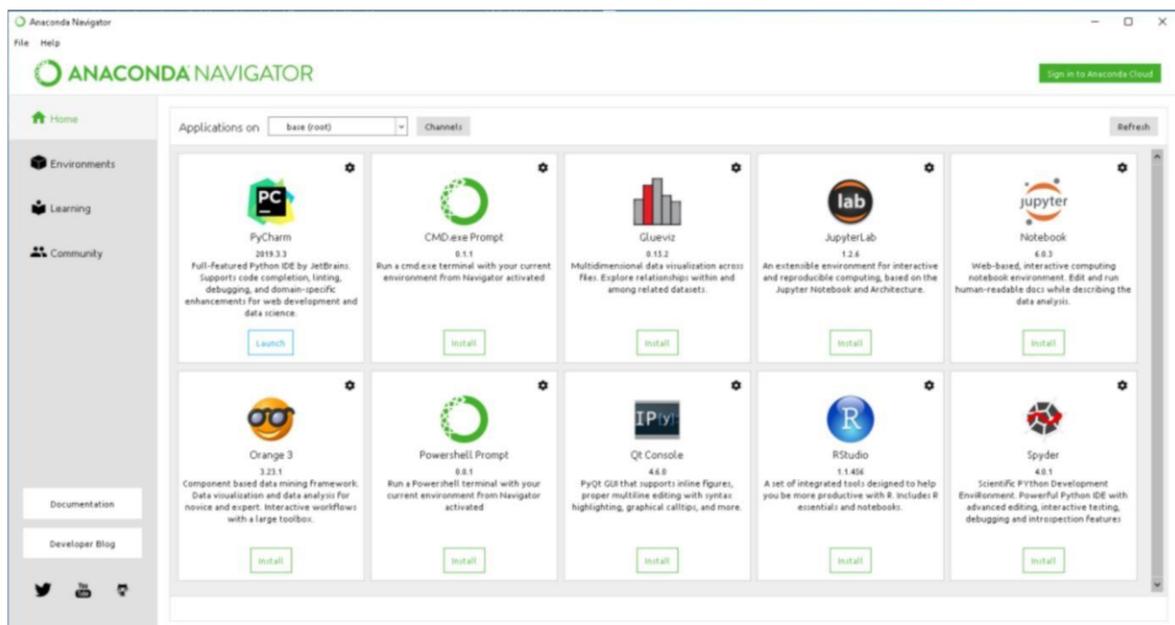


Figure 4.1 : Anaconda Navigator [94]

d Spyder

Acronyme de « Scientific PYthon Development EnviRonment », Sypder (figure 4.2), est un environnement de développement puissant en langage Python, conçu pour Python. Il offre une combinaison unique, des fonctionnalités avancées d'édition, d'analyse, de débogage et de profilage d'un outil de développement complet avec l'exploration de données, l'exécution interactive, l'inspection approfondie et les capacités de visualisation d'un package scientifique [95].

Cette multiplateforme se caractérise par :

- Le surlignage de syntaxe personnalisable
- La disponibilité des 'breakpoints' (débogage et points d'arrêt conditionnels)
- L'exécution interactive qui permet d'exécuter une ligne, un fichier, une cellule, etc.
- L'exécution des configurations pour les sélections de répertoires de travail, les options de ligne de commande, la console actuelle/dédiée/externe, etc.
- L'annulation des variables automatiquement (ou entrer dans le débogage)
- La navigation dans les cellules, les fonctions, les blocs... effectuée via l'explorateur.
- La fourniture d'une introspection de code en temps réel (la possibilité d'examiner quels sont les fonctions, mots-clés et classes, ce qu'ils font et quelles informations, ils contiennent) ;
- La prise en charge toutes les commandes magiques lpython ;
- La disponibilité également des fonctionnalités telles que, l'aide l'explorateur de fichiers, la recherche de fichiers, etc.

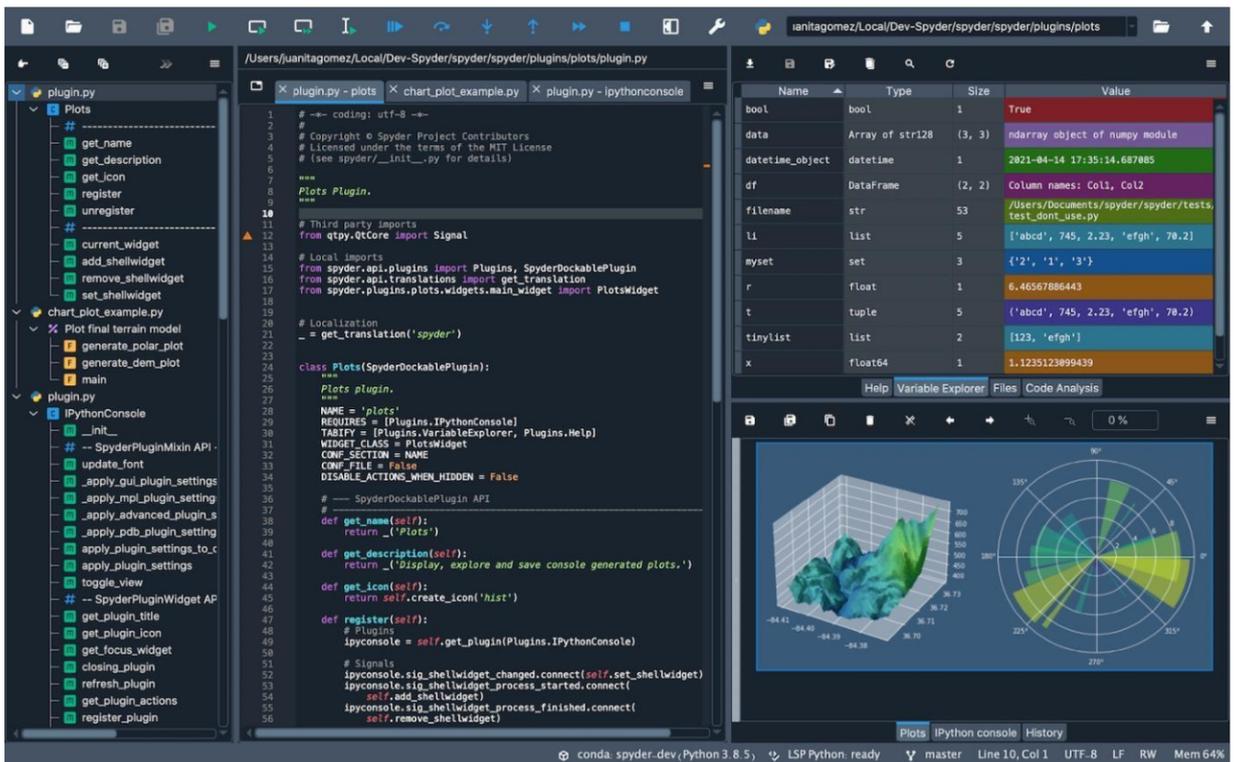


Figure 4.2 : Environnement Spyder [95]

e Tensorflow

Tensorflow est une bibliothèque ‘open source’ du ML, créée par Google, permettant de développer et d’exécuter des applications, du Machine et du Deep Learning. Son API front-end de développement d’applications, repose sur le langage de programmation Python, tandis que l’exécution de ces applications, s’effectue en C++ haute-performance [96].

Cette plateforme (figure 4.3) permet notamment d’entraîner et d’exécuter des réseaux de neurones, pour la classification de chiffres écrits à la main, la reconnaissance de formes, les modèles séquence à séquence, pour la traduction automatique, ou encore le traitement naturel du langage.

Nombreux sont les avantages du Tensorflow, en plus de la facilité de son utilisation et du déploiement. Nous citons :

- Le framework facilite l'implémentation d'algorithmes et, permet au développeur de se focaliser sur la logique générale d'une application.
- Le mode « eager execution » permet d'évaluer et de modifier, toutes les opérations des graphes, de façon séparée et transparente.
- La suite de la visualisation TensorBoard, permet d'inspecter la façon dont les graphiques, fonctionnent par le biais d'un tableau de bord interactif basé web.

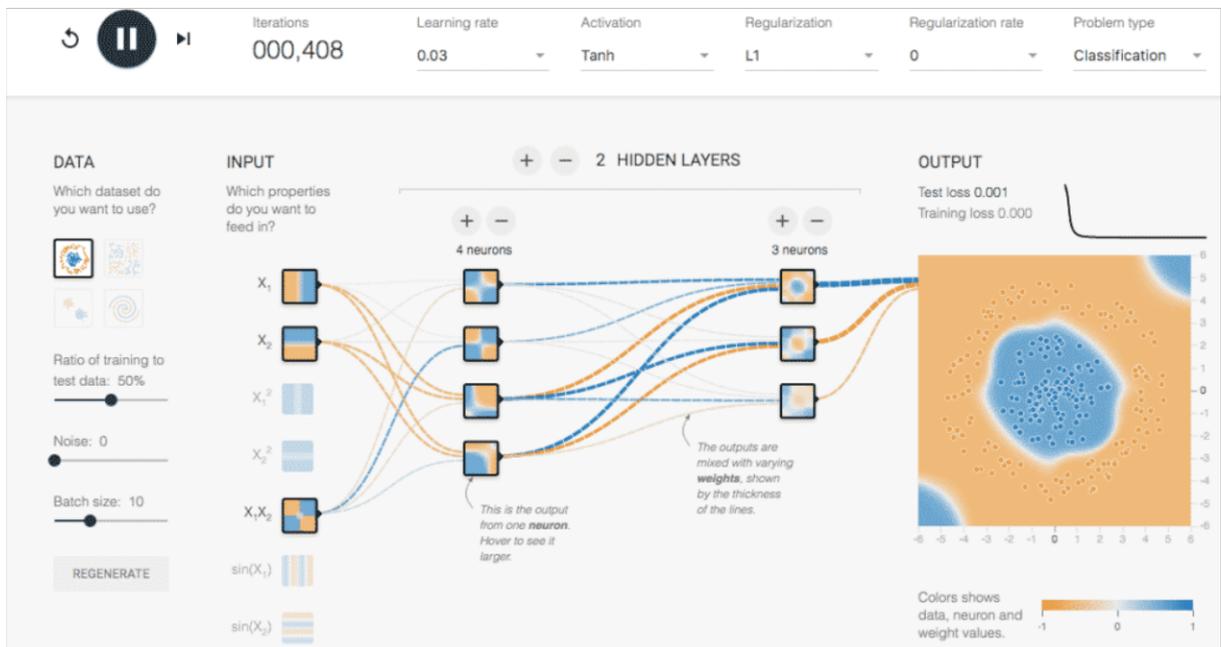


Figure 4.3 : Plateforme Tensorflow [96]

f Keras

Keras (figure 4.4) est l'une des principales API, des réseaux de neurones de haut niveau. C'est une bibliothèque Open Source, écrite en Python et interfaçable avec TensorFlow, CNTK (Microsoft Cognitive Toolkit) et Theano. Elle a été développée avec pour objectif de permettre des expérimentations rapides. Être capable d'aller de l'idée au résultat, avec le plus faible délai possible, étant la clef d'une recherche efficace [97].

Cette bibliothèque est :

- Simple : Keras réduit la charge cognitive du développeur permettant de se concentrer sur les parties les plus importantes du problème.
- Flexible : il adopte le principe de divulgation progressive de la complexité (*progressive disclosure of complexity*) ; les flux de travail simples doivent être facile et rapides, contrairement aux flux de travail arbitrairement avancés, qui doivent être possibles, via un chemin clair qui s'appuie sur ce qui a déjà été pris.
- Puissant : il offre des performances et une évolutivité à la pointe de l'industrie. Il est utilisé par des organisations et des entreprises, telles que la NASA, Youtube ou Waymo.

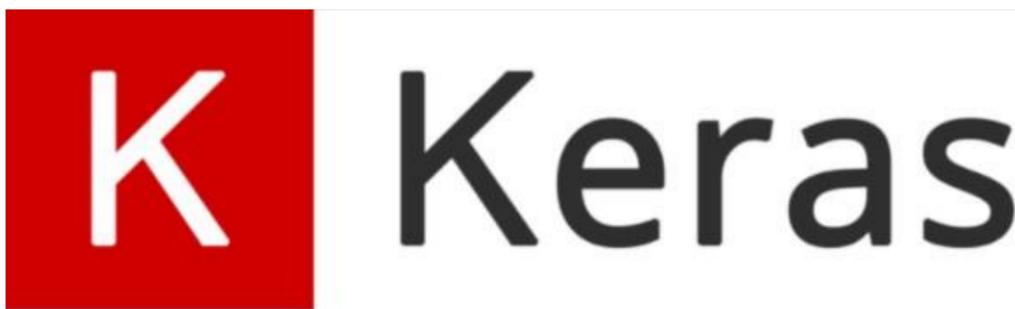


Figure 4.4: Bibliothèque Keras [97]

g Numpy

Numpy ou *Numerical Python*, est une bibliothèque open source en langage Python, qui manipule des matrices ou tableaux multidimensionnels, elle permet d'effectuer des opérations mathématiques et statistiques basiques ou avancées sur des arrays et des matrices multidimensionnelles avec peu de lignes de code.

Cette bibliothèque permet non-seulement, d'effectuer des calculs logiques et mathématiques sur des tableaux et des matrices, mais elle fournit également des tableaux, qui utilisent moins de mémoire et d'espace de stockage. Plus simple et efficace, elle offre aussi de meilleures performances en termes de vitesse d'exécution [98].

NumPy est la base de SciPy, un regroupement de bibliothèques Python, autour du calcul scientifique.

h Scikit-learn

Scikit-learn [99] est une librairie Python, destinée à l'apprentissage automatique. De nombreuses bibliothèques d'algorithmes sont proposées, dans son framework. Elle comprend des outils et des fonctions pour la préparation des données, la séparation de la base de données, la normalisation, le traitement des valeurs manquantes, la sélection des variables et même, la déduction de la dimension du jeu de données. Elle est créée pour s'harmoniser avec d'autres bibliothèques libres, telles que Numpy.

i Matplotlib

Matplotlib [100] est une bibliothèque Python conçue afin de tracer et visualiser des données sous formes graphiques. Elle peut être utilisée dans des scripts Python, le shell Python et IPython, le notebook Jupyter, des serveurs d'application web et dans quatre outils d'interface graphique. Elle permet une combinaison avec les bibliothèques python de calcul telles que Numpy. Le module « *matplotlib.pyplot* » fournit une interface spécialement adaptée avec IPython, pour la création des graphiques simples.

j Splitfolders

Splitfolders [93] est une bibliothèque en langage Python, servant à diviser automatiquement et de manière aléatoire, la base de données en sous-ensembles **d'entraînement, de validation et de test**, avant de les placer respectivement dans des dossiers contenant les mêmes noms (train, val, test).

Base de données

D'origine égyptienne, la base de données « BUSI » (Breast Ultrasound Images), mise à notre disposition, a été collectée en 2018 [69]. Elle contient des images échographiques mammaires de femmes âgées entre 25 et 75 ans, rassemblant un total de 780 images ainsi que leurs masques au format PNG, d'une taille d'image moyenne de 500x500 pixels (tableau 4.1). Ces images sont classées en trois parties distinctes : bénignes, malignes et normales (cf figure 4.5).

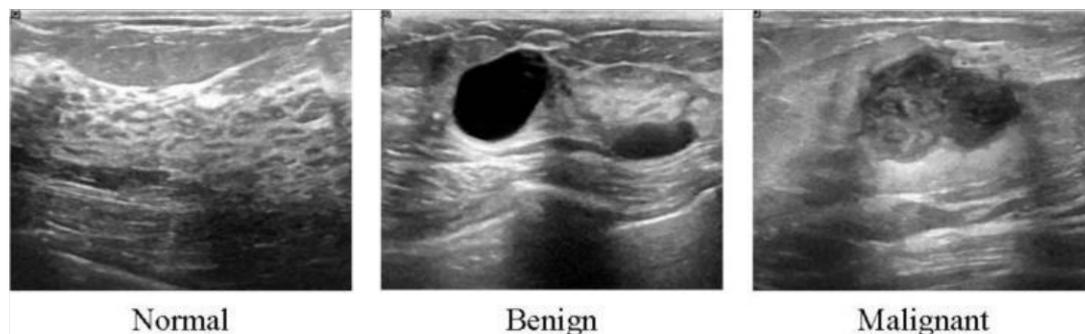


Figure 4.5 : Exemples d'images contenus dans le dataset BUSI [69]

Bénignes	Malignes	Normales	Total
891	421	266	1578

Tableau 4.1 : Répartition de l'ensemble de données en classes (bénignes, malignes, normales)

Préparation des données de l'application 'BCNNV2'

La répartition de l'ensemble des données est primordiale, dans l'entraînement des modèles de l'apprentissage profond. A cet égard, le système 'BCNNV2' est mis en œuvre, en suivant la division de la base en trois ensembles.

- 90% des données sont utilisées pour l'entraînement (train set), pour la détermination des paramètres des réseaux ;
- 5% des données sont consacrées à la validation (valid set), pour l'identification des hyperparamètres ;

- Et enfin 5% des données sont employées pour le test (test set) assignées à l'évaluation finale du modèle (tableau 4.2).

Une deuxième répartition des données (tableau 4.3) a été effectuée, pour permettre une deuxième comparaison des résultats :

- 80% des données sont consacrées à l'ensemble d'entraînement ;
- 10% des données sont utilisées pour la validation ;
- Et enfin, 10% des données restantes, sont destinées à l'évaluation du modèle final à travers l'ensemble du test.

La fonction «ratio» de la bibliothèque «splitfolders» s'est chargée, de répartir d'une façon automatique et rapide l'ensemble de données en trois classes (train, val, test).

Train	Validation	Test	Total
1260	157	161	1578

Tableau 4.2 : Répartition 80-10-10 de l'ensemble de données en classes (train, val, test)

Train	Validation	Test	Total
1418	78	82	1578

Tableau 4.3 : Répartition 90-5-5 de l'ensemble de données en classes (train, val, test)

Avant de faire une augmentation des données, il est important d'uniformiser les images en appliquant un redimensionnement à l'ensemble de données grâce à l'instruction «image_resize».

Après avoir uniformiser les clichés, la classe «datagenerator» utilisée sous Keras, permet d'effectuer plusieurs transformations sur les images (figure 4.6), afin d'augmenter le nombre de données, sans pour autant perdre les caractéristiques importantes.

Pour notre approche, nous avons utilisé les opérations suivantes :

- `rotation_range`: une fonction permettant de réaliser une rotation entre 0° et 180° ;
- `width_shift_range`: une fonction afin d'appliquer une translation verticale ;
- `height_shift_range` : pour une translation horizontale des images ;
- `shear_range` : une fonction qui permet d'effectuer un froissement des images (angle de cisaillement dans le sens inverse des aiguilles d'une montre) ;
- `zoom_range` : afin d'appliquer un recadrage aléatoire sur les images ;
- `horizontal_flip` : une fonction pour effectuer une rotation horizontale ;
- `fill_mode`: une technique de remplissage des nouveaux pixels apparus, lors d'une translation ou une rotation.

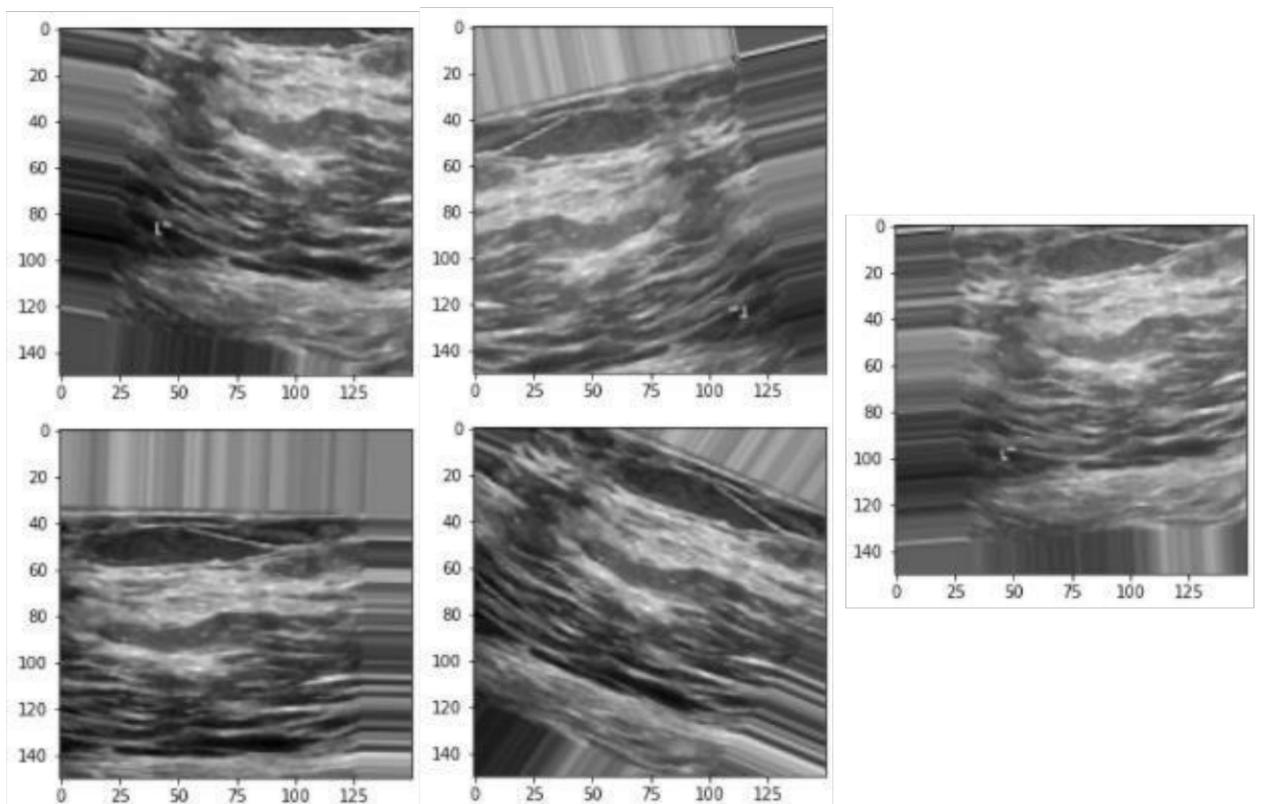


Figure 4.6 : Augmentation des données

Architecture du système

Le système 'BCNNV2' classe les images échographiques mammaires, en trois classes : maligne, bénigne et normale, suivant trois modèles des réseaux convolutifs pré-entraînés : le VGG16, l'Inception V3 et le Resnet50. Dans ce cadre, en premier lieu, nous avons pris soin de remplacer les dernières couches de chaque modèle, par des couches fully connected (FC) avant de les affiner en suivant deux stratégies :

- Un fine-tuning partiel : il se résout à geler les paramètres de certaines couches du réseau pré-entraîné. De ce fait, les couches non-gelées sont entraînées, sur les nouvelles données ainsi que le classifieur.
- Un fine-tuning total : dans cette stratégie, toutes les couches du modèle sont entraînées.

Les tableaux qui suivent (tableaux 4.3, 4.4, 4.5, 4.6, 4.7 et 4.8), décrivent les architectures des couches rajoutées, sur chaque modèle pré-entraîné (VGG16, Inception-V3, ResNet50) suivant les deux stratégies mentionnées ci-dessus.

Noms des Couches	Tailles	Paramètres
Flatten	25088	0
Dense (FC)	4092	Activation 'Relu'
Dropout	4092	0
Batch_normalization	4092	16368
Dense_1 (FC)	1024	Activation 'Relu'
Dropout_1	1024	0
Dense_2 (FC)	3	Activation 'Softmax'

Tableau 4.4 : Paramètres des couches ajoutées au modèle VGG16 avec un fine-tuning partiel

Noms des Couches	Tailles	Paramètres
Global_Average_Pooling2D_1	2048	0
Dense_3(FC)	524	Activation 'Relu'
Dropout_2	524	0
Dense_4 (FC)	524	Activation 'Relu'
Dropout_3	524	0
Dense_7(FC)	3	Activation 'Softmax'

Tableau 4.5 : Paramètres des couches ajoutées au modèle Inception V3 avec un fine-tuning partiel

Noms des Couches	Tailles	Paramètres
Conv2d_2	(5,5,32)	589856
Conv2d_3	(3,3,32)	9248
Dropout_3	(3,3,32)	0
Global_average_pooling2D	32	0
Dense_4 (FC)	1024	Activation 'Relu'
Dropout_4	1024	0
Dense_5 (FC)	524	Activation 'Relu'
Dropout_5	524	0
Dense_6 (FC)	400	Activation 'Relu'
Dense_3 (FC)	3	Activation 'Softmax'

Tableau 4.6 : Paramètres des couches ajoutées au modèle ResNet 50 avec un fine-tuning partiel

Noms des Couches	Tailles	Paramètres
Conv2D	5x5x32	147488
Conv2D_1	3x3x32	9248
Dropout	3x3x32	0
Max_pooling2D	1x1x32	0
Flatten	32	0
Dense (FC)	1024	Activation 'Relu'
Dropout_1	1024	0
Dense_1	3	Activation 'Softmax'

Tableau 4.7 : Paramètres des couches ajoutées au modèle VGG16 avec un fine-tuning total

Noms des Couches	Tailles	Paramètres
Conv2d_1440	3x3x32	589856
Conv2d_1441	1x1x32	9248
Dropout_17	1x1x32	0
Global_average_pooling2d	32	0
Dense_4 (FC)	1024	Activation 'Relu'
Dropout_18	1024	0
Dense_5 (FC)	3	Activation 'Softmax'

Tableau 4.8 : Paramètres des couches ajoutées au modèle Inception-V3 avec un fine-tuning total

Noms des Couches	Tailles	Paramètres
Conv2D	5x5x32	589856
Conv2D_11	3x3x32	9248
Dropout	3x3x32	0
Global_average_pooling2d	32	0
Dense (FC)	1024	Activation 'Relu'
Dropout_1	1024	0
Dense_1 (FC)	3	Activation 'Softmax'

Tableau 4.9 : Paramètres des couches ajoutées au modèle ResNet50 avec un fine-tuning total

Résultats

Modèle VGG16 avec un fine-tuning total

Notre étude a débuté par l'entraînement du réseau, qui se base sur le modèle pré-entraîné VGG16. L'architecture du modèle a été modifiée, en remplaçant son MLP par une unique couche entièrement connectée (FC). Le réseau possède 14,908,291 paramètres, où 193,603 sont entraînaibles.

Le tableau 4.10, illustre les paramètres utilisés, au niveau de chaque couche de convolution et de pooling du réseau.

Type	Patch size x nombre de convolution / Stride	Ouput
Conv	3x3x64/1	224x224x64
Conv	3x3x64/1	224x224x64
Pool	2x2x64/2	112x112x64

Conv	3x3x128/1	112x112x128
Conv	3x3x128/1	112x112x128
Pool	3x3x128/2	56x56x128
Conv	3x3x256/1	56x56x256
Conv	3x3x256/1	56x56x256
Conv	3x3x256/1	56x56x256
Pool	3x3x256/2	28x28x256
Conv	3x3x512/1	28x28x512
Conv	3x3x512/1	28x28x512
Conv	3x3x512/1	28x28x512
Pool	3x3x512/2	14x14x512
Conv	3x3x512/1	14x14x512
Conv	3x3x512/1	14x14x512
Conv	3x3x512/1	14x14x512
Pool	3x3x512/2	7x7x512

Tableau 4.10 : Grandes lignes de l'architecture proposée

La colonne 'Output' représente les résultats obtenus, après l'application d'un produit de convolution (figure 4.7), d'un maxpooling (figure 4.8), d'une couche flatten (figure 4.9) et d'un dropout (figure 4.10).

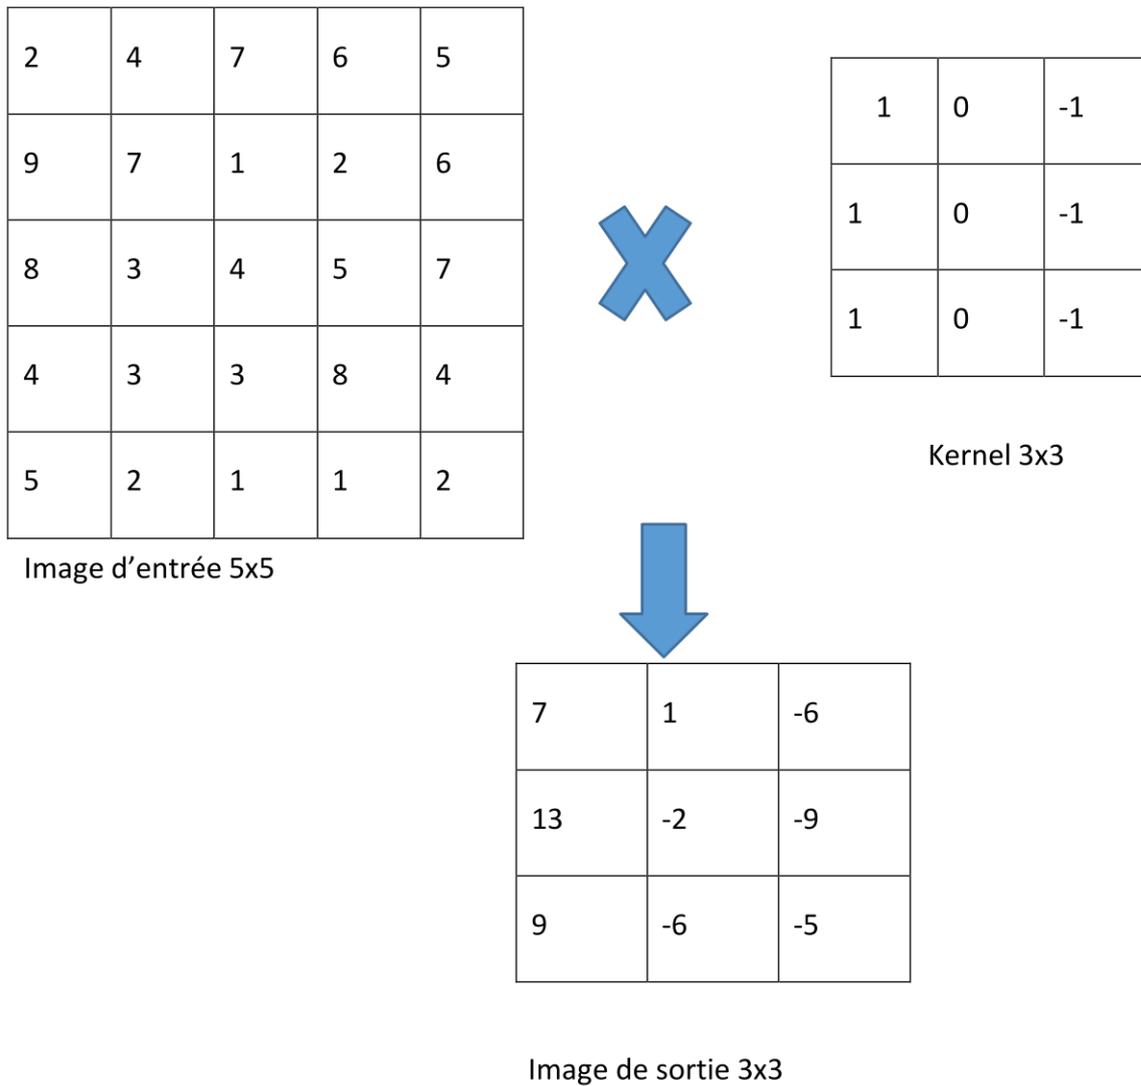


Figure 4.7 : Exemple d'une convolution 3x3 avec un stride de 1

Image d'entrée

2	3	1	9
4	7	3	5
8	2	2	2
1	3	4	5



7	9
8	5

Image de sortie

Figure 4.8 : Exemple d'un maxpool 2x2 avec un stride de 2

5	4	6
1	2	3
7	9	8



5
4
6
1
2
3
7
9
8

Figure 4.9 : Exemple de l'opération flatten

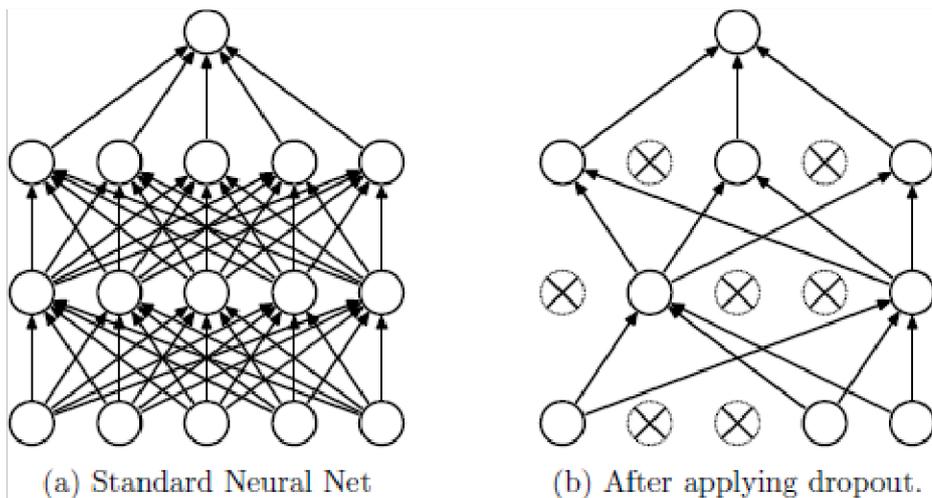


Figure 4.10 : Exemple de Dropout ou abandon

La dernière couche contient 3 nœuds, avec une fonction d'activation softmax, qui permet de distribuer les probabilités pour chaque classe.

Afin de choisir l'algorithme d'apprentissage qui convient, nous avons expérimenté les paramètres d'optimisation «Adam», «Adadelta» et «SGD» avec le modèle décrit dans le tableau 4.7.

Les poids de l'entraînement sont récupérés de l'ImageNet «weight='imagenet'».

Les hyperparamètres des optimiseurs ainsi que le momentum, sont initialisés à leurs valeurs par défaut. Le taux d'apprentissage est fixé à 0.001, la taille du batch est de 16 pour l'apprentissage et 4 pour le test.

Le tableau ci-dessous illustre les résultats obtenus :

Erreur	
Adam	0.2500
Adadelta	0.7364
SGD	0.4200

Tableau 4.11 : Erreur d'exécution de chaque algorithme après 70 itérations

Afin de minimiser l'erreur d'apprentissage, les algorithmes « Adam » et « Adadelta », appliquent des gradients adaptatifs, qui progressent dès le début du processus. Toutes les expérimentations effectuées (figure 4.11), nous ont amenées à choisir le meilleur modèle type, avec une exactitude de 93% à la 70ème époque, cela en utilisant l'optimiseur Adam.

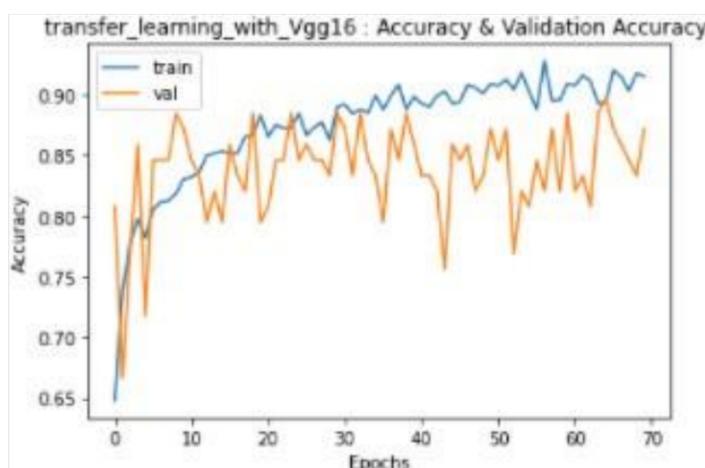


Figure 4.11: Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques

A chaque augmentation du nombre d'itérations, l'exactitude augmente pour les ensembles d'entraînement et de validation. Ceci démontre, une relation de corrélation entre les deux ensembles.

La figure 4.12, illustre clairement l'instabilité de l'erreur de la validation. Cette dernière ne s'étend en un rien vers le zéro et varie du 0.3 au 0.8 après 70, tout le contraire de l'erreur de d'entraînement qui diminue progressivement à chaque augmentation d'époques.

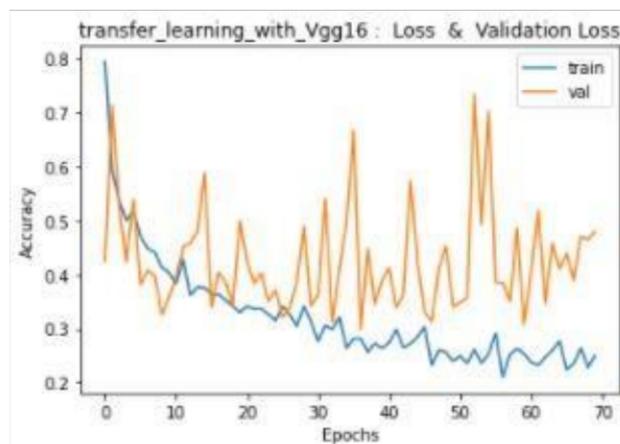
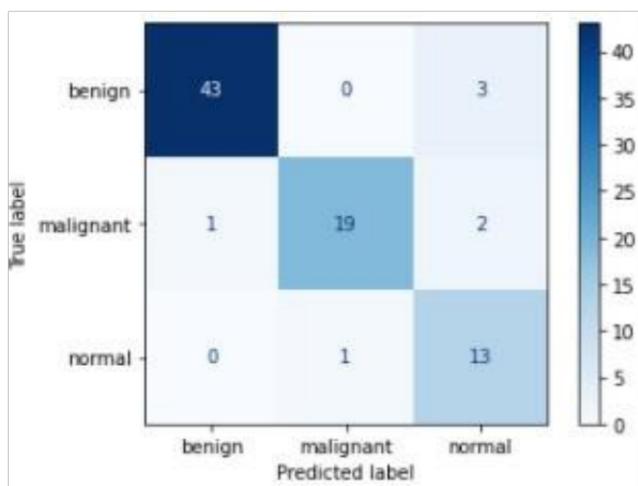


Figure 4.12 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques

Le système résultant, a été évalué par la matrice de confusion montrée dans la figure 4.13.



```
Confusion Matrix
[[43  0  3]
 [ 1 19  2]
 [ 0  1 13]]
```

B) Matrice de confusion

A) Tableau de confusion

Figure 4.13 : Matrice de confusion pour VGG16

Les vrais positifs : lorsqu'une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 19.

Les vrais négatifs : il s'agit lorsqu'une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 13.

Les faux positifs : sont représentés lorsqu'une classe bénigne, est présentée comme maligne. Le nombre de faux positifs est de 1.

Les faux négatifs : lorsqu'une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 2.

Le tableau 4.12, illustre le rapport de classification, qui indique les critères d'évaluation du système étudié.

	Précision	Rappel	F1-score
Bénigne	0.98	0.93	0.96
Maligne	0.95	0.86	0.90
Normale	0.72	0.93	0.81
Accuracy (test)	0.91		

Tableau 4.12 : Résultats obtenus avec la matrice de confusion

Modèle VGG16 avec un fine-tuning partiel

Afin d'améliorer les résultats obtenus lors des applications du modèle précédent, nous avons utilisé la stratégie du fine-tuning partiel. Tout d'abord, nous avons créé un modèle VGG16, sans les 'top layers' avec des poids pré-entraînés sur imageNet, en précisant que les poids ne seront pas modifiés (geler les poids). Dans ce cas, l'apprentissage ne les modifiera pas pour les quatre premières couches.

L'architecture du modèle est montrée dans le tableau 4.4. Pour les mêmes configurations que le fine-tuning total, les figures ci-dessous illustrent les résultats du modèle le plus approprié.

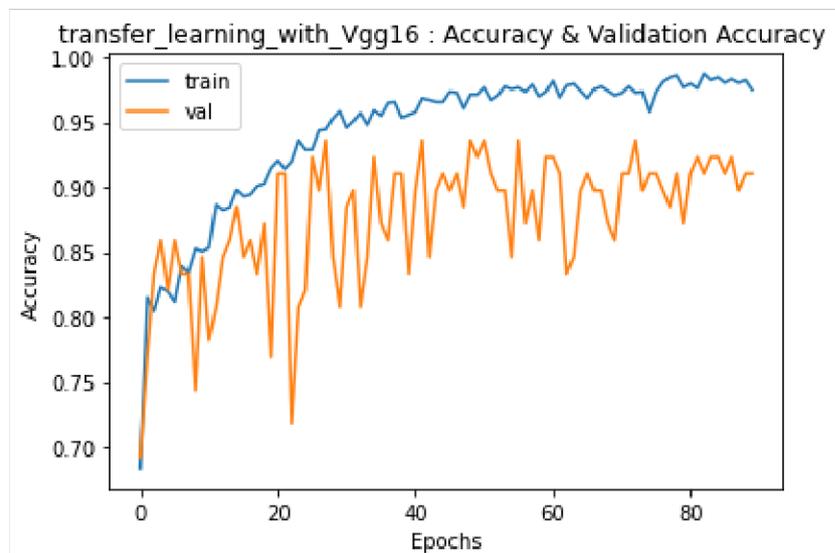


Figure 4.14 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

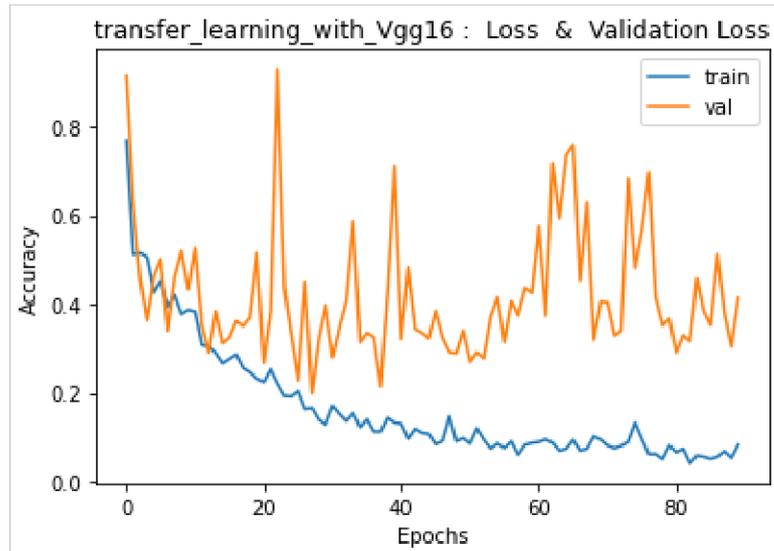


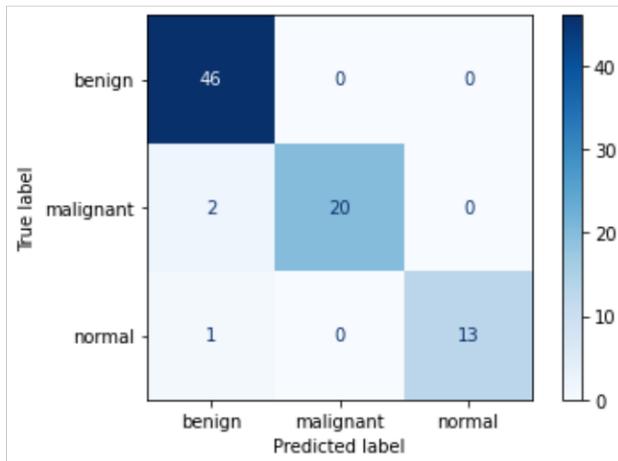
Figure 4.15 : Evaluation de la fonction de perte des ensembles d’entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

A partir des deux figures 4.14 et 4.15, nous constatons que les courbes de ce réseau constituent, un bon ajustement des données, avec une large exactitude de 97% (figure 4.16), pour l’ensemble d’entraînement et 91% pour l’ensemble de validation après 70 époques.

```
loss: 0.0831 - acc: 0.9746
```

Figure 4.16 : Pourcentage d’exactitude et de perte de l’ensemble d’entraînement

La matrice de confusion (figure 4.17) pour ce modèle, montre un bien meilleur résultat, que précédemment. Néanmoins, la difficulté à reconnaître les classes à 100% reste présente, cela est principalement dû, au faible nombre d’échantillons dans la base de données.



A) Table de confusion

```
Confusion Matrix
[[46  0  0]
 [ 2 20  0]
 [ 1  0 13]]
```

B) Matrice de confusion

Figure 4.17 : Matrice de confusion pour VGG16 avec un fine tuning partiel

Les vrais positifs : lorsqu'une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 20.

Les vrais négatifs : lorsqu'une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 13.

Les faux positifs : sont représentés lorsqu'une classe bénigne, est présentée comme maligne. Le nombre de faux positifs est de 0.

Les faux négatifs : lorsqu'une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 0.

Le tableau 4.13, illustre le rapport de classification qui indique les critères d'évaluation du système étudié avec un fine-tuning partiel.

Classe	Précision	Rappel	F1-score
Bénigne	0.94	1.00	0.97
Maligne	1.00	0.91	0.95
Normale	1.00	0.93	0.96
Accuracy (test)	0.96		

Tableau 4.13 : Rapport de la classification obtenu avec la matrice de confusion

Le tableau 4.14 présente la matrice de confusion des 3 classes. Pour cela, il suffit de calculer la sensibilité et la spécificité, suivant les formules ci-dessous :

Classe 1	Classe 2	Classe 3	FN
N11	N12	N13	(N12+N13)
N21	N22	N23	(N21+N23)
N31	N32	N33	(N31+N32)
(N21+N31)	(N12+N32)	(N13+N23)	FP

Tableau 4.14 : Matrice de confusion avec 3 classes

Spécificité :

$$\text{Classe 1} = (N22+N33)/(N21+N31+N22+N33)$$

$$\text{Classe 2} = (N11+N33)/(N12+N32+N11+N33)$$

$$\text{Classe 3} = (N11+N22)/(N13+N23+N11+N22)$$

Sensibilité :

$$\text{Classe 1} = N11/(N11+N12+N13)$$

$$\text{Classe 2} = N22/(N21+N22+N23)$$

$$\text{Classe 3} = N33/(N31+N32+N33)$$

Le tableau 4.15 présente la spécificité et la sensibilité pour le modèle VGG16 avec un fine tuning.

Classes	VGG16 avec un fine-tuning total		VGG16 avec un fine-tuning partiel	
	Spécificité	Sensibilité	Spécificité	Sensibilité
Bénigne	0.97	0.93	0.92	1.00
Maligne	0.98	0.86	1.00	0.91
Normale	0.93	0.93	1.00	0.92

Tableau 4.15 : Spécificité et sensibilité du modèle VGG16

Modèle Inception-V3 avec un fine-tuning total

Dans la seconde partie de l'étude, c'est le modèle inception-V3, qui est adopté. Le réseau est entraîné de la même manière que le VGG16, avec les deux stratégies du fine-tuning.

Pour la première partie, nous avons commencé par modifier l'architecture du modèle pré-entraîné de base, en remplaçant son MLP, par 7 couches dont 2 couches de convolution, une couche Pooling, 2 dropout ainsi que 2 couches entièrement connectées.

Il possède 22,438,755 paramètres. Pour chaque époque, la taille des lots d'entraînement, est fixée à 16, tandis que celles de la validation et du test, restent fixées à 4. Le taux d'apprentissage est de 0.001. La figure suivante résume l'architecture du modèle

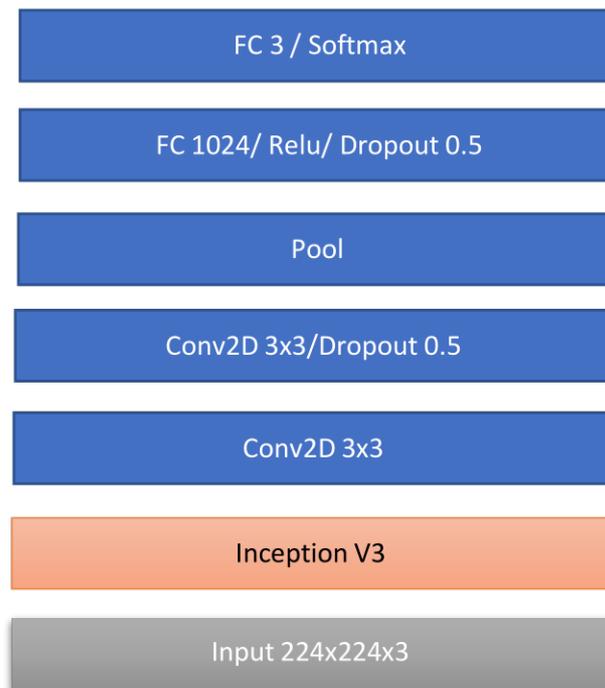


Figure 4.18 : Modèle Inception-V3 avec un fine tuning

Tout comme pour le VGG16, nous avons expérimenté les paramètres d'optimisation «Adam», «Adadelta» et «SGD» avec le modèle décrit dans le tableau 4.8. Les poids de l'entraînement sont issus de l'ImageNet. Les hyperparamètres des optimiseurs, sont initialisés par défaut. Le taux d'apprentissage est fixé à 0.001, la taille du batch est de 16 pour l'entraînement et 4 pour la validation et le test.

Les résultats obtenus sont résumés dans les figures 4.19, 4.20 et le tableau 4.16.

Erreur	
Adam	0.5329
Adadelta	0.5179
SGD	0.2885

Tableau 4.16 : Erreur d'exécution de chaque algorithme après 70 époques

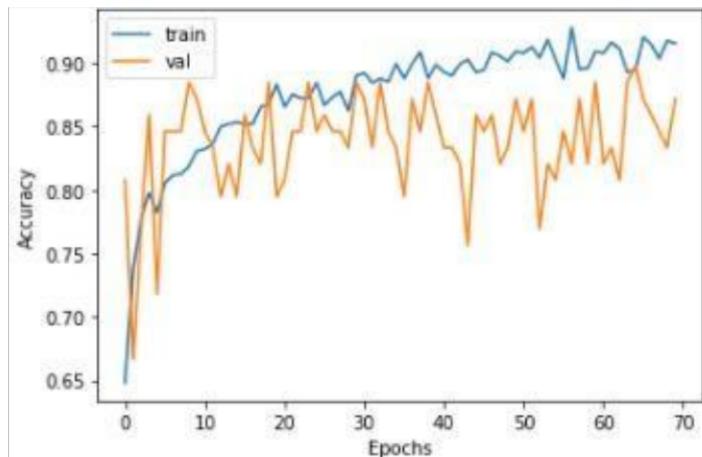


Figure 4.19: Evaluation de l'exactitude des ensembles d'entraînement et de validation du modèle Inception-V3 en fonction du nombre des époques

Toutes les expérimentations nous ont amenée à choisir le meilleur modèle type, avec une exactitude de 80% à la 70ème époque, cela en utilisant l'optimiseur Adam.

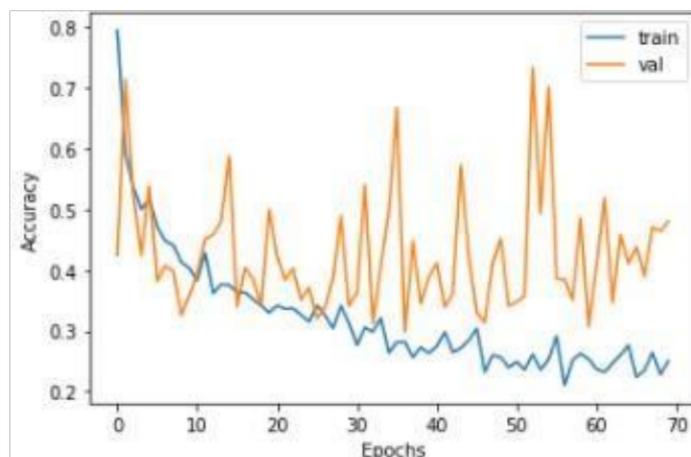


Figure 4.20: Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques

Une instabilité claire est remarquée pour l'erreur de validation, elle reste variée entre 0.3 et 0.8, contrairement à l'erreur d'entraînement qui se réduit à chaque augmentation d'époque.

La matrice de confusion (figure 4.21) résume les résultats obtenus lors de la phase du test.

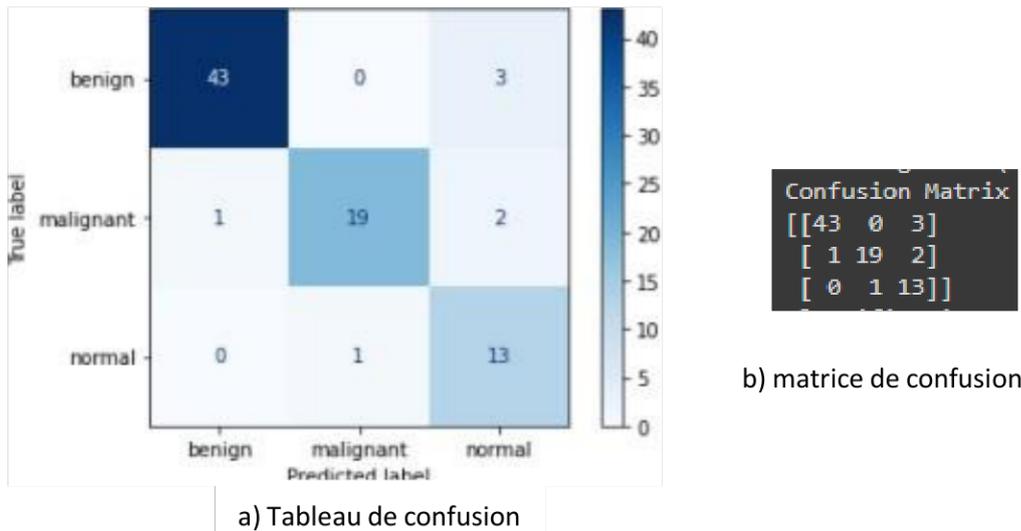


Figure 4.21 : Matrice de confusion pour inception-V3

Les vrais positifs : lorsqu'une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 19.

Les vrais négatifs : lorsqu'une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 13.

Les faux positifs : sont représentés lorsqu'une classe bénigne est présentée comme maligne. Le nombre de faux positifs est de 1.

Les faux négatifs : lorsqu'une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 2.

Les critères d'évaluation du système étudié sont illustrés dans le tableau 4.17.

Classe	Précision	Rappel	F1-score
bénigne	0.98	0.93	0.96
maligne	0.95	0.86	0.90
normale	0.72	0.93	0.81
Accuracy (test)			0.91

Tableau 4.17 : résultats obtenus avec la matrice de confusion

Modèle Inception-V3 avec un fine-tuning partiel

Dans le cas du fine tuning partiel du modèle inception-V3, nous avons en premier lieu gelé les 'Top layers' du modèle Inception-V3 et par la suite, rajouté les couches comme montré, dans le tableau 4.5. Pour les mêmes configurations que le fine-tuning total du modèle, nous avons obtenu les résultats représentés par les figures 4.22 et 4.23.

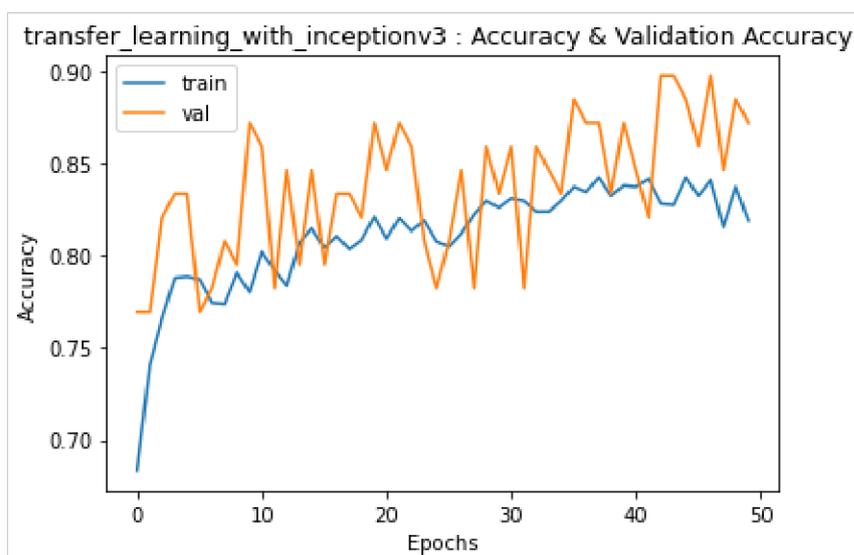


Figure 4.22 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

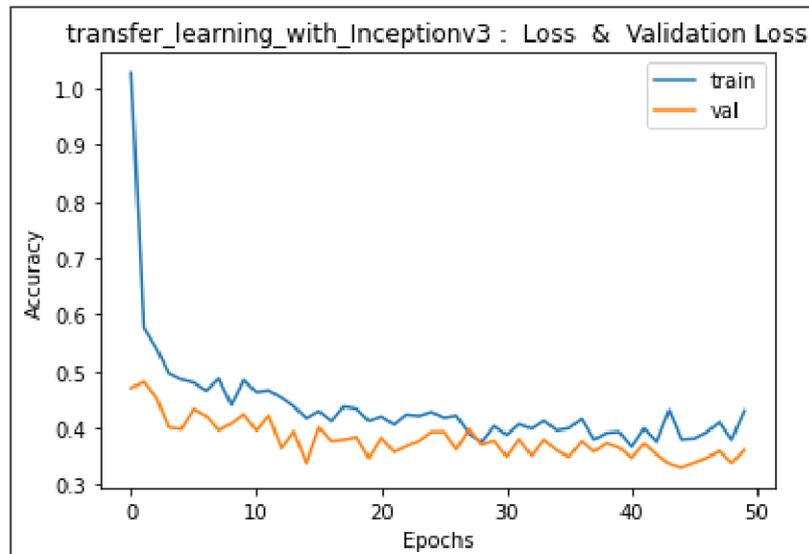


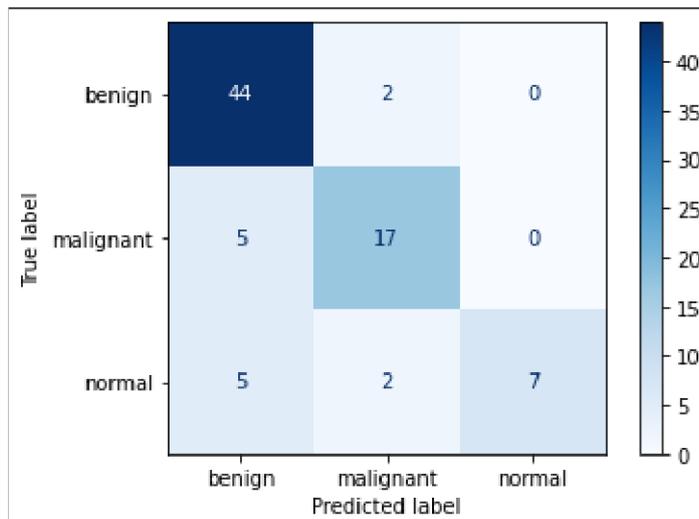
Figure 4.23 : Evaluation de la fonction de perte des ensembles d’entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

Les deux graphes, démontrent une baisse de la précision pour ce modèle, par rapport au VGG16, avec une exactitude de 81.88% pour l’ensemble d’entraînement et de validation et 87.18% pour l’ensemble de test après 50 époques (figure 4.24).

```
loss: 0.4306 - acc: 0.8188
```

Figure 4.24 : Pourcentage d’exactitude et de perte de l’ensemble d’entraînement

La matrice de confusion (figure 4.25) résume les résultats obtenus lors de la phase du test.



a) Tableau de confusion

```
Confusion Matrix
[[44  2  0]
 [ 5 17  0]
 [ 5  2  7]]
```

b) matrice de confusion

Figure 4.25 : Matrice de confusion pour inception-V3

Les vrais positifs : une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 17.

Les vrais négatifs : une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 7.

Les faux positifs : sont représentés lorsqu'une classe bénigne est présentée comme maligne. Le nombre de faux positifs est de 2.

Les faux négatifs : une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 0.

Les tableaux 4.18 et 4.19, illustrent respectivement le rapport de classification des critères d'évaluation du système étudié, avec le fine-tuning partiel ainsi que la sensibilité et la spécificité du modèle Inception-V3 utilisant les 2 stratégies.

	Précision	Rappel	F1-score
bénigne	0.81	0.96	0.88
maligne	0.81	0.77	0.79
normale	1.00	0.50	0.67
Accuracy (test)	0.83		

Tableau 4.18: Résultats obtenus avec la matrice de confusion

Classes	Inception-V3 avec un fine-tuning total		Inception-V3 avec un fine-tuning partiel	
	Spécificité	Sensibilité	Spécificité	Sensibilité
Bénigne	0.97	0.93	0.71	0.96
Maligne	0.98	0.86	0.96	0.77
Normale	0.93	0.93	0.90	0.50

Tableau 4.19 : Spécificité et sensibilité du modèle Inception-V3

Modèle ResNet50 avec un fine-tuning total

Le système 'BCNN' étudie un troisième modèle pré-entraîné, le ResNet. Le réseau a été entraîné de la même manière que le VGG et l'Inception-V3, en l'utilisant avec les deux stratégies de fine-tuning partiel et total. La formation s'est faite, en commençant par la modification de l'architecture de base du modèle, pour ensuite remplacer son MLP, par deux couches de convolutions, une couche Pooling, deux Dropout et enfin deux couches entièrement connectées. A cet effet, le modèle créé, possède au total 24,223,683 paramètres, dont 635,971 entraînaibles. Pour chaque époque, la taille des lots d'entraînement est fixée à 16, celle de la validation et du test à 4. Le taux d'apprentissage est de 0.001.

La figure 4.26 illustre l'architecture du modèle Resnet avec un fine tuning.

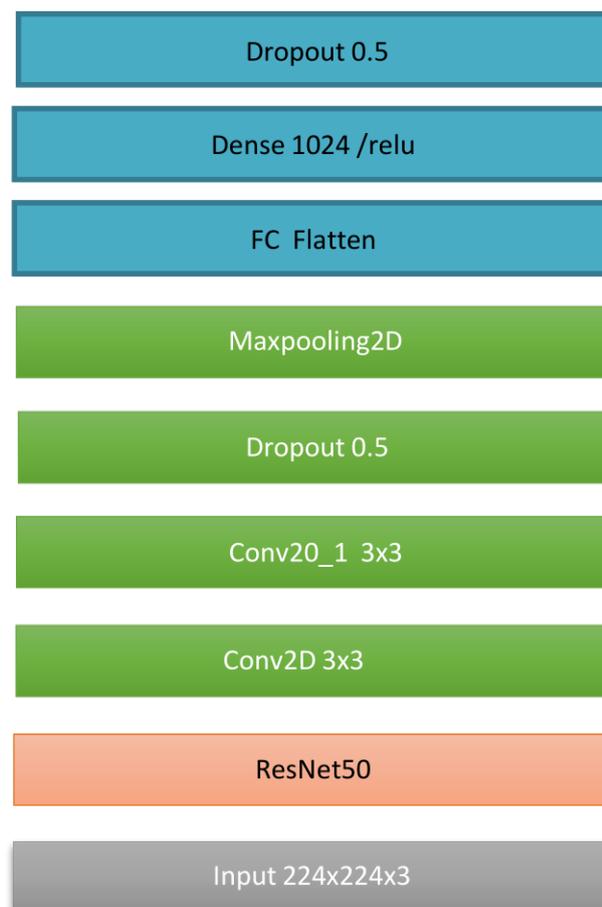


Figure 4.26 : Modèle ResNet avec fine tuning

Le modèle décrit dans le tableau 4.9, a été expérimenté avec les trois paramètres d'optimisation «Adam» et «Adadelta». Les résultats obtenus sont donnés par le tableau 4.20, ainsi que les figures 4.27 et 4.28.

Erreur	
Adam	0.6695
Adadelta	0.9374

Tableau 4.20: Erreur d'exécution de chaque algorithme après 70 époques

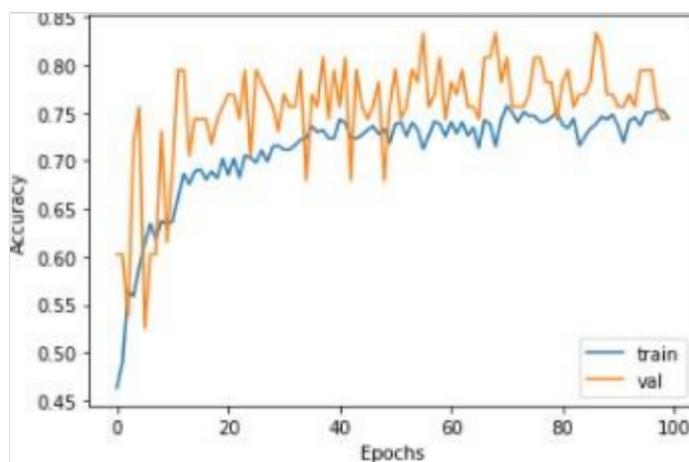


Figure 4.27: Evaluation de l'exactitude des ensembles d'entraînement et de validation du modèle ResNet50 en fonction du nombre des époques

Toutes les expérimentations nous ont amenée à choisir le meilleur modèle type avec une exactitude de 74% à la 100ème époque, cela en utilisant l'optimiseur Adam.

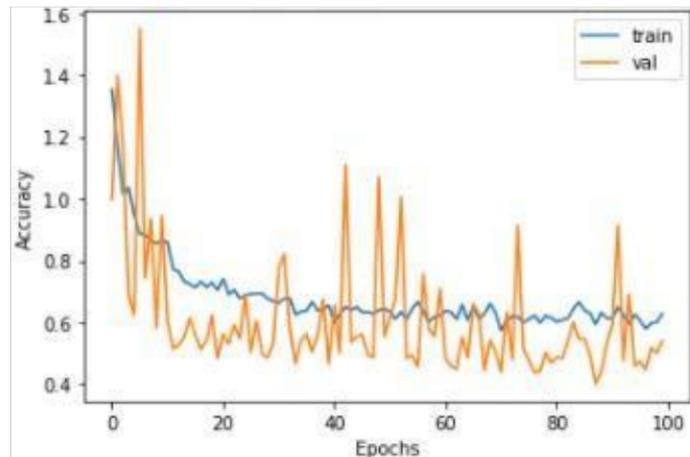
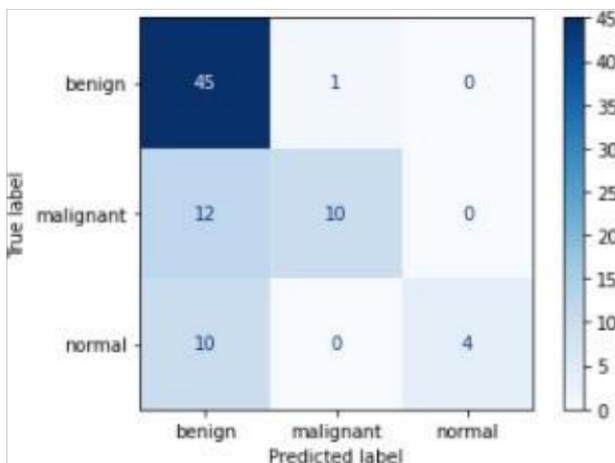


Figure 4.28 : Evaluation de la fonction de perte des ensembles d’entraînement et de validation en fonction du nombre des époques

D’après la figure ci-dessus, l’erreur de validation est clairement instable. Elle varie entre 1.6 et 0.4, contrairement à l’erreur d’entraînement, qui se réduit à chaque augmentation d’époques, sans pour autant atteindre le zéro.

La figure qui suit affirme les résultats obtenus, dans la matrice de confusion de la figure 4.29.



a) Tableau de confusion

```
Confusion Matrix
[[45  1  0]
 [12 10  0]
 [10  0  4]]
```

b) Matrice de confusion

Figure 4.29 : résultats obtenus avec la matrice de confusion

Les vrais positifs : une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 10.

Les vrais négatifs : une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 4.

Les faux positifs : sont représentés lorsqu'une classe bénigne est présentée comme maligne. Le nombre de faux positifs est de 0.

Les faux négatifs : une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 0.

Le tableau 4.21 illustre les critères d'évaluation du système étudié.

Classe	Précision	Rappel	F1-score
Bénigne	0.67	0.98	0.80
Maligne	0.91	0.45	0.61
Normale	1.00	0.29	0.44
Accuracy (test)	0.72		

Tableau 4.21 : Résultats obtenus avec la matrice de confusion

Modèle ResNet50 avec un fine-tuning partiel

Tout comme les deux modèles précédents, nous avons gelé les 'Top layers', du modèle ResNet-50, pour ensuite rajouter les couches comme illustré dans le tableau 4.6. Les configurations restent les mêmes, que celles du fine-tuning total. Ce qui suit, montre les résultats obtenus (figures 4.30 et 4.31).

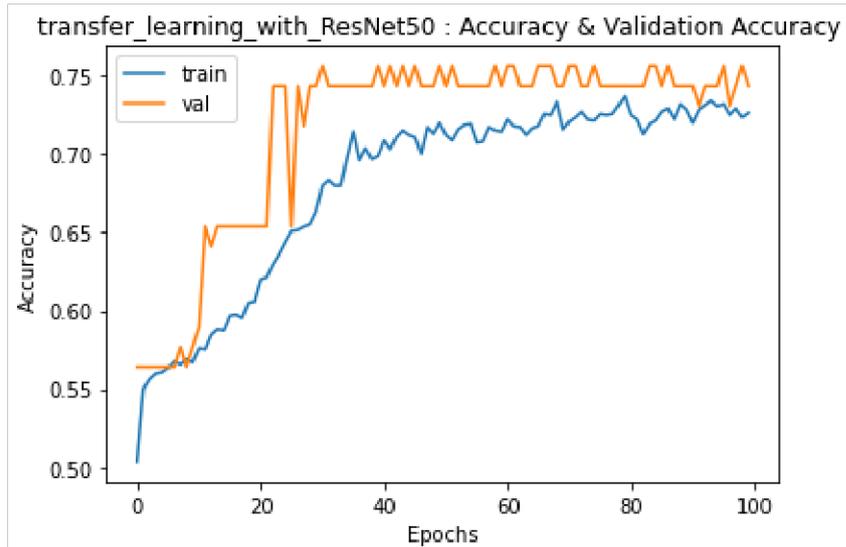


Figure 4.30 : Evaluation de l'exactitude des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

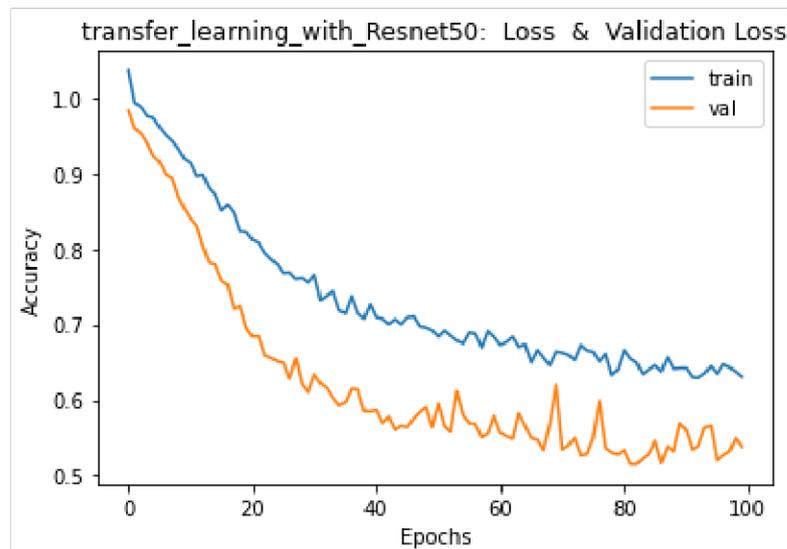


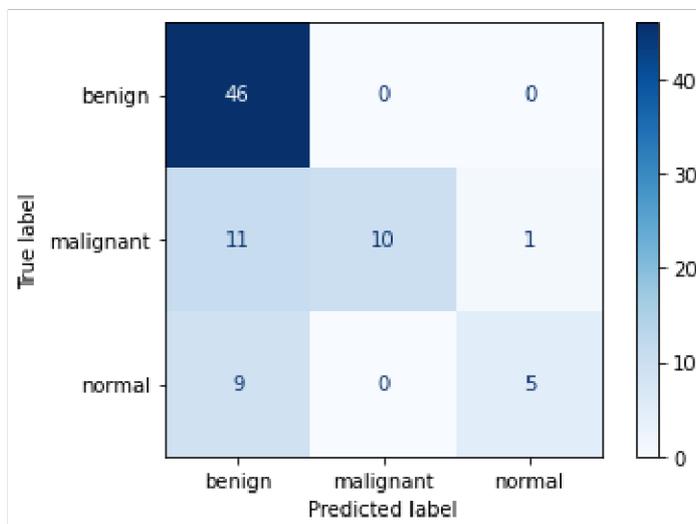
Figure 4.31 : Evaluation de la fonction de perte des ensembles d'entraînement et de validation en fonction du nombre des époques pour un fine-tuning partiel

La figure 4.30, montre une augmentation de l'exactitude de l'ensemble d'entraînement (72%) (figure 4.32). Pour l'ensemble de validation, elle est de 74% et pour l'ensemble de test, elle est de 75%.

loss: 0.6308 - acc: 0.7264

Figure 4.32: Pourcentage d'exactitude et de perte de l'ensemble d'entraînement

La figure qui suit affirme les résultats obtenus, dans la matrice de confusion de la figure 4.33.



```
Confusion Matrix
[[46  0  0]
 [11 10  1]
 [ 9  0  5]]
```

a) Tableau de confusion

b) matrice de confusion

Figure 4.33 : Résultats obtenus avec la matrice de confusion

Les vrais positifs : une classe maligne est présentée comme maligne. Le nombre des vrais positifs est de 10.

Les vrais négatifs : une classe normale est présentée comme normale. Le nombre des vrais négatifs est de 5.

Les faux positifs : sont représentés lorsqu'une classe bénigne est présentée comme maligne. Le nombre de faux positifs est de 0.

Les faux négatifs : une classe maligne est représentée comme normale. Le nombre de faux négatifs est de 1.

Les tableaux 4.22 et 4.23, illustrent respectivement le rapport de classification ainsi que la spécificité et la sensibilité du modèle ResNet50:

	précision	rappel	F1-score
bénigne	0.70	1	0.82
maligne	1.00	0.45	0.62
normale	0.83	0.36	0.50
Accuracy	0.74		

Tableau 4.22 : Résultats obtenus avec la matrice de confusion

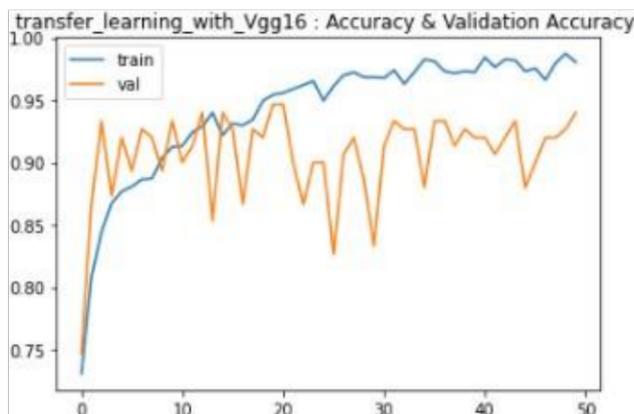
Classes	ResNet50 avec un fine-tuning total		ResNet50 avec un fine-tuning partiel	
	Spécificité	Sensibilité	Sensibilité	Spécificité
Bénigne	0.39	0.98	1.00	0.43
Maligne	0.98	0.45	0.45	1.00
Normale	1.00	0.29	0.36	0.98

Tableau 4.23 : Spécificité et sensibilité du modèle Resnet50

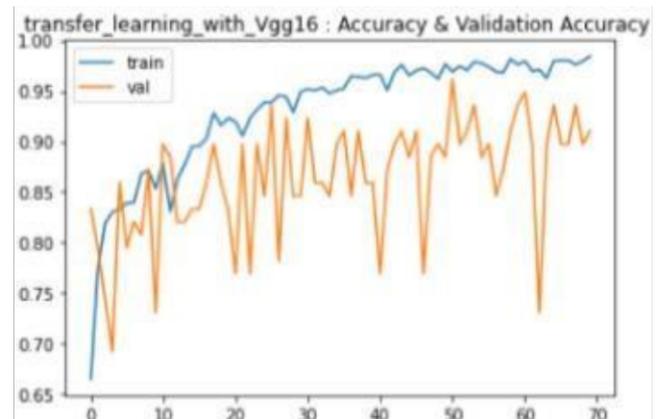
Discussion et comparaison

Diverses expérimentations ont été effectuées par le système 'BCNN'. En considérant la taille de l'image, il a été démontré qu'il était primordial de leur faire un redimensionnement. Dans un premier temps, les dimensions des images ont été réglés à 500x500, les résultats obtenus n'ont pas été concrets, il a été obligatoire de changer le redimensionnement en 224x224. L'approche des finalités, a démontré clairement un meilleur choix des proportions.

La répartition des ensembles, reste tout aussi importante que le redimensionnement. En effet, une répartition de 90-5-5 a engendré de bien meilleures finalités, qu'une répartition 80-10-10 (80% ensemble d'entraînement, 10% ensemble de validation et 10% ensemble de test) (figure 4.34).



B) Split 80-10-10



A) Split 90-5-5

Figure 4.34 : Résultats obtenus avec une répartition 80-10-10 et une répartition 90-5-5 du modèle VGG16 avec un fine-tuning partiel

D'autres configurations ont été variées, en partant des tailles de lots (batch), le taux d'apprentissage et le nombre d'itérations ; afin de classifier les différentes catégories de la base (BUSI). Chaque critère a démontré son importance. Une mauvaise configuration a conduit à de mauvaises performances. De ce fait, pour d'excellentes performances, la taille la plus favorable des batchs est entre 16 et 32, le nombre d'époques doit être supérieur à 40 et le taux d'apprentissage peut prendre l'une des deux valeurs 0.001 et 0.0001. Ces configurations permettent le traitement de plusieurs exemples et donc, un apprentissage plus rapide et plus précis. En effet, la variété du nombre des paramètres, joue un rôle notable pour le développement des performances.

Les architectures choisies dans les tableaux précédents (4.3, jusqu'à 4.8), ont été modifiées à plusieurs reprises. À partir de cela, nous pouvons conclure donc que le nombre de couches de convolutions, ainsi que le nombre d'unités dans les couches entièrement connectées, influencent grandement, la répartition des poids du réseau. Plus le nombre d'unités cachées augmente, plus la potentialité d'une meilleure performance sera envisageable. L'utilisation de grandes couches connectées (4024, 1024) permet une grande complexité. Cependant, ces mêmes couches possèdent plus de poids à estimer.

Le bloc le plus crucial des réseaux de neurones à convolution, est le bloc de convolution. Ce dernier possède des paramètres tels que, la taille des convolutions, peut varier entre les chiffres 1, 3 et 7. L'influence de la taille des convolutions reste cependant, négligeable sur le nombre total de poids à estimer.

La structure du CNN est certes un paramètre déterminant, mais le choix des paramètres de l'algorithme d'optimisation, reste décisif et peut altérer les résultats finaux.

L'optimiseur «SGD» est le plus adapté au modèle Inception-V3, l'optimiseur «Adadelta» n'a été compatible avec aucun des modèles précédents, l'optimiseur «Adam» a, toutefois, démontré être compatible et de loin avec nos modèles, menant à des performances adéquates (tableau 4.24).

Optimiseur Modèle	ADAM	ADADELTA	SGD
VGG16	92.50%	68%	88%
Inception V3	92.50%	80%	91%
ResNet50	72.50%	72%	/

Tableau 4.24: Comparaison entre les différents modèles développés

Selon les résultats mentionnés précédemment, la structure la plus adaptée à notre modèle a été de loin celle du VGG16. Ceci démontre que notre base de données est plus adaptée à un enchaînement classique de couches de convolutions et de pooling, que des blocs tels qu'Inception et ResNet.

Malgré leurs hautes performances connues, les résultats affichés au final n'ont pas été adéquats, cela revient à la base de données qui possède un nombre limité d'images, tandis que ces architectures demandent au minimum 5000 images pour d'excellentes performances.

Le modèle VGG16, est donc notre modèle final. L'apprentissage du modèle a été prolongé jusqu'à 100 époques, tout en sauvegardant les paramètres à chaque époque. L'augmentation du nombre d'époques amène à une baisse considérable, des probabilités de dropout, augmentant ainsi la capacité de la généralisation du modèle. Par conséquent, l'état restauré, nous a offert les meilleures performances du système étudié.

Dans la finalité des calculs, l'apprentissage de 100 époques avec un taux d'apprentissage de 0.001 est illustré par le tableau 4.25.

	Erreur	Exactitude
Modèle VGG 16 Final (%)	0.2558	0.9250

Tableau 4.25 : Résultats finaux du système 'BCNN' sur l'ensemble test

Conclusion

Ce chapitre a analysé la classification des différentes pathologies mammaires à travers des images échographiques, en concevant et développant le système 'BCNN', basé sur trois architectures des réseaux de neurones convolutifs pré-entraînés, le VGG16, l'Inception-V3 et le ResNet50. Après de multiples variations, l'étude comparative a révélé que le modèle le plus adapté à notre système, est le VGG16 avec une précision qui dépasse les 92%.

Conclusion générale

L'initiation à la recherche réalisée dans le cadre de ce mémoire, s'inscrit dans les objectifs de l'équipe, "IMAD", du département d'électronique du laboratoire LATSI, pour la conception de systèmes d'aide au diagnostic en imagerie médicale.

Pour les radiologues, l'interprétation exacte des clichés échographiques en un temps limité, représente un réel défi à surmonter. La nature bruitée des images, oblige les patients à effectuer une série d'exams anatomopathologiques, retardant ainsi leur prise en charge ce qui augmente féroceement, leur taux de mortalité.

Dans ce cadre, l'étude effectuée, se rapportant à l'élaboration d'un système d'aide à la détection automatique de tumeurs mammaires, via les images ultrasonores, utilise des approches d'apprentissage profond basées sur des architectures des réseaux neuronaux convolutifs pré-entraînés.

A travers une conception armée de couches de convolutions, pour l'extraction des différentes caractéristiques, et de couches de pooling maximal, pour le sous-échantillonnage spatial, le modèle VGG16, l'architecture Inception-V3 et la structure ResNet50 ont été conçus. Le système 'BCNNV2' a été ajusté et affiné, suivant les stratégies de fine-tuning total et partiel, construisant des modèles basés sur l'apprentissage par transfert, afin de les tester sur une base de données échographiques publique et récente.

L'utilisation des modèles Inception-V3 et ResNet50 n'ont hélas pas apporté de résultats très satisfaisants. En effet, lors des différentes expérimentations, leurs exactitudes respectives obtenues, varient entre 60% et 85%. Cela est dû en grande partie, aux images limitées de la base de données.

La richesse des couches du réseau VGG16, a contribué grandement à la classification des tumeurs mammaires, suivant les stratégies du fine tuning adoptées. Le modèle s'est révélé être le plus adéquat pour notre système avec une précision de 92%, en utilisant l'optimiseur «Adam», avec un taux d'apprentissage de 0.001.

Les travaux futurs possibles, pourraient éventuellement explorer les modèles YOLO (You Only Look Once) ou SSD (Single Shot MultiBox Detector), sur des images échographiques 3D et 4D, ou encore explorer d'autres modalités du cancer du sein.

Bibliographie

- [1] OMS, Cancer, mars 2021, <https://www.who.int/fr/news-room/fact-sheets/detail/cancer> , date de consultation : 26/04/2121
- [2] The Global Observatory, 12 algeriafactsheet, fiche descriptive, mars 2021, <https://gco.iarc.fr/today/data/factsheets/populations/12-algeria-fact-sheets.pdf> , date de consultation : 26/04/2021
- [3] Hyuna Sung, Jacques Ferlay, Rebecca L Siegel, Mathieu Laversanne, Isabelle Soerjomataram, Ahmedin Jemal, Freddie Bray, Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries, Article de revue, CA: a cancer journal for clinicians, Vol 71, Num 3, p 209-249, Mai 2021. <https://pubmed.ncbi.nlm.nih.gov/33538338/> date de consultation: 26/04/2021
- [4] Société canadienne du cancer, Les seins, <https://www.cancer.ca/fr-ca/cancer-information/cancer-type/breast/breast-cancer/the-breasts/?region=on> , date de consultation : 01/05/2021
- [5] Marie-Céline Ray, Tissus adipeux, <https://www.futura-sciences.com/sante/definitions/corps-humain-tissu-adipeux-15691/> date de consultation : 01/05/2021
- [6] Marie Thirion, Tissus conjonctif et adipeux, https://www.santeallaitementmaternel.com/se_former/connaître_anatomie_mere/tissus_conjonctif_et_adipeux.php date de consultation : 01/05/2021
- [7] Eric Sebban, L'anatomie du sein: Les différents types de tumeurs bénignes et malignes, mars 2019, <https://www.docteur-eric-sebban.fr/cancer-du-sein/diagnostic-cancer-sein/anatomie-et-pathologies-du-sein/> date de consultation : 01/05/2021
- [8] B. Lafarge-Bart, E. Barrager, Gynécologie, 2015-01-01, Volume 30, Numéro 1, Pages 1-7, <https://www-clinicalkey-fr.sndl1.arn.dz/#!/content/emc/51-s2.0-S0246106414564304> date de consultation : 02/05/2021
- [9] L. Levy, H. Tristant, A. Reizine, B. Martin, B. Bennaim, C. Balleyguier et M. Brisa, Radiologie et imagerie médicale - génito-urinaire - gynéco-obstétricale - mammaire, 2003-01-01, Volume 16, Numéro 2, Pages 1-20, <https://www-clinicalkey-fr.sndl1.arn.dz/#!/content/emc/51-s2.0-S1879854303341205?scrollTo=%23hl0000629> date de consultation : 02/05/2021
- [10] M. Nikpayam MD, E. Oueld Es Cheikh MD et C. Uzan MD, PhD, Traité de médecine AKOS, 2019-10-01, Volume 22, Numéro 4, Pages 1-5, <https://www-clinicalkey-fr.sndl1.arn.dz/#!/content/emc/51-s2.0-S1634693919569265> , date de consultation : 04/05/2021
- [11] Institut national du cancer, Les maladies du sein - Cancer du sein, <https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Cancer-du-sein/Les-maladies-du-sein#:~:text=La%20tumeur%20b%C3%A9nigne%20qui%20se,%C3%A9coulement%20du%20mamelon%2C%20la%20gyn%C3%A9comastie> , date de consultation : 05/05/2021

Bibliographie

[12] Fédération Nationale des centres de lutte contre le cancer (FNCLCC) : La ligue contre le cancer, Comprendre le cancer du sein : guide d'information et de dialogue à l'usage des personnes malades et de leurs proches, p9-18, janvier 2007

[13] Collège Français des Pathologistes (CoPath), Item 309 (ex item 159) – Tumeurs du sein, UVF – Université Médicale Virtuelle Francophone, 2013, http://campus.cerimes.fr/anatomie-pathologique/enseignement/anapath_32/site/html/cours.pdf date de consultation : 05/05/2021

[14] Le Cancer.FR, Cancer du sein : Définition ,<https://lecancer.fr/dossiers/le-cancer-ce-qu-il-faut-savoir/les-differents-types-de-cancer/cancer-du-sein/cancer-du-sein-definition/> date de consultation : 05/05/2021

[15] OMS, Cancer du sein, mars 2021, <https://www.who.int/fr/news-room/factsheets/detail/breast-cancer> date de consultation : 05/05/2021

[16] The Global Observatory, 20-Breast-fact-sheet, fiche descriptive, Décembre 2020, <https://gco.iarc.fr/today/data/factsheets/cancers/20-Breast-fact-sheet.pdf> date de consultation : 05/05/2021

[17] Institut National du cancer, Symptômes - Cancer du sein, <https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Cancer-du-sein/Symptomes> date de consultation : 05/05/2021

[18] Check 4 Cancer, Breast Cancer Risk Factors & Symptoms | OneStop Breast Cancer Clinics | Check4Cancer, <https://www.check4cancer.com/advice-and-awareness/breast-cancer> date de consultation: 05/05/2021

[19] Steven A Narod, Ten types of breast cancer?, The Lancet, Vol 380, Num 9849, P 1212-1213, Octobre 2012, <https://www-clinicalkey-fr.snd11.arn.dz/#!/content/journal/1-s2.0-S0140673612607818> date de consultation : 05/05/2021

[20] Société canadienne du cancer, Tumeurs cancéreuses du sein <https://www.cancer.ca/fr-ca/cancer-information/cancer-type/breast/breast-cancer/cancerous-tumours/?region=on> date de consultation : 05/05/2021

[21] E. Sebban, Cancer du sein métastatique : quelle approche thérapeutique ?, mai 2020, https://www.docteur-eric-sebban.fr/?s=cancer+du+sein+m%C3%A9tastatique&post_type=post date de consultation : 05/05/2021

[22] J. Lansac et L. Ouldamer, Gynécologie pour le praticien, Elsevier Masson, 2018, Chapitre 19, p 276-300 <https://www-clinicalkey-fr.snd11.arn.dz/#!/content/book/3-s2.0-B9782294756375000193?scrollTo=%23hl0001936> date de consultation : 07/05/2021

[23] CEA Commissariat à l'énergie atomique et aux énergies alternatives, Imagerie médicale, Livret pédagogique, 2017, ISSN 1637-5408.

Bibliographie

[24] Z. Lezar, Cancer du sein, Juillet 2019, 10.13140/RG.2.2.21498.44482, https://www.researchgate.net/publication/334524502_cancer_du_sein date de consultation : 11/05/2021

[25] G. Oldrini, Dépistage en IRM mammaire, Décembre 2017, (PDF) Dépistage en IRM mammaire (researchgate.net) date de consultation : 11/05/2021

[26] T.H. Dao et A. Rahmouni, IRM en pratique clinique, Elsevier Masson, 2017, Chapitre 36, 605-652, <https://www-clinicalkey-fr.sndi1.arn.dz/#!/content/book/3-s2.0-B9782294725029000365?scrollTo=%23hl0001090> date de consultation : 11/05/2021

[27] J. Stinès, Imagerie du sein, Elsevier Masson, Octobre 2012, ISBN 978-2-294-72960-7 https://books.google.dz/books?id=RVQD_vxFR8IC&printsec=frontcover&dq=IMAGERIE+DU+SEIN&hl=fr&sa=X&ved=2ahUKEwiindjJwsHwAhWDTUIHVVC5oQ6AEwAHoECAIQAg#v=onepage&q=IMAGERIE%20DU%20SEIN&f=false date de consultation le 11/05/2021

[28] J. DÜRRLEMAN, Valeur diagnostique de la mammographie synthétique sans et avec tomosynthèse, Thèse pour le diplôme d'état de docteur en médecine, Université Paris Descartes, 2015

[29] I. Cheikhrouhou, Description et classification des masses mammaires pour le diagnostic du cancer du sein, Sciences pour l'ingénieur, Traitement des images et du signal, Université d'Evry-Val d'Essonne - France, 2012

[30] L. Levy, J. Michelin, G. Teman, B. Martin, A. Dana, A. Lacan, D. Meyer, Techniques d'exploration radiologique du sein (mammographie, échographie, imagerie par résonance magnétique), Editions Scientifiques et Médicales Elsevier, Radiodiagnostic - Principes et techniques d'imagerie, 34-800-A-10, 2001, p20

https://fr.slideshare.net/imma-dr/techniques-dexploration-radiologique-du-sein-mammographie?from_action=save

Consulté le 11/05/2021

[31] Paul G. Newman MD*, Grace S. Rozycki MD, FACS*, Surgical Clinics of North America, Volume 78, Issue 2, 1 Avril 1998, p179-195

<https://www.sciencedirect.com/science/article/abs/pii/S003961090570308X#!>

Consulté le : 03/06/2021

[32] Anne Tardivon, Imagerie de la femme : sénologie (Coll. Imagerie médicale), Lavoisier Médecine Sciences, 978-2-257-70605-8, 2014, p161-182 <https://books.google.dz/books?id=6ZrKBAAAQBAJ&pg=PA309&dq=appareil+echographie+mammaire&hl=fr&sa=X&ved=2ahUKEwjd19uL1bLxAhVS4OAKHUMuC3YQ6AEwBnoECAsQAQAg#v=onepage&q=appareil%20echographie%20mammaire&f=false> date de consultation : 03/06/2021

[33] Lysane, Anthony, Yannis, Marie. Le matériel utilisé, <http://tpe-echographie-2014.over-blog.com/2014/12/le-materiel-utilise.html> date de consultation : 03/06/2021.

Bibliographie

- [34] medTandem, Les bases physiques de l'échographie | Découverte de l'échographie <https://www.youtube.com/watch?v=RQQmjRJ0ykw> , date de consultation : 10/06/2021
- [35] L. Deschildre, G. Hurtevent-Labrot, J. Savage, H. Bercez, S. Taieb, L. Ceugnart*. Tumeurs bénignes et mastopathies complexes Aspects radiologiques. 28es journées de la SFSPM, Lille, novembre 2006.
- [36] Dr de Korvin, Semiologie Echographique Lexique Birads Classification ACR Masse et Microcalcifications, Institut Rennais du Sein, CLCC Rennes, 2018.
- [37] C. Balu-Maestro, Cancer du sein, Springer-Verlag, 978-2-287-25174-0, Paris, 2006, p49-66
- [38] Haute Autorité de Santé, Actualisation du référentiel de pratiques de l'EPS – Dépistage et prévention du cancer du sein, 2 avenue du Stade de France - 93218 Saint-Denis La Plaine CEDEX, N° ISBN : 978-2-11-139064-5, 2015.
- [39] Brigitte Séroussi, Jacques Bouaud, Systèmes informatiques d'aide à la décision en médecine : panorama des approches utilisant les données et les connaissances, Pratique Neurologique – FMC, Volume 5 n° 5, ISSN 18787762, 2014, p 303-316.
- [40] HAMADOUCHE Meroua, NEDJAR Djamel, Détection et classification des tumeurs dans les tissus mammaires par la machine à vecteur de support(SVM), Mémoire de Master Académique en Electronique, Université Abdelhamid Ibn Badis Mostaganem, 2019.
- [41] Numerica, L'intelligence artificielle: Les machines sont-elles déjà plus intelligentes que nous?, BoD - Books on Demand, ISBN 978-2-492-12604-8, 2020, p8-12. https://books.google.dz/books?id=Vff6DwAAQBAJ&printsec=frontcover&dq=intelligence+artificielle+machine+learning+et+deep+learning&hl=fr&sa=X&redir_esc=y#v=onepage&q&f=false date de consultation : 03/06/2021.
- [42] L. Bastien, Deep Learning ou apprentissage profond : définition, concept, blog LeBigData.fr, 2018, <https://www.lebigdata.fr/deep-learning-definition> , date de consultation 10/06/2021.
- [43] IONOS Digitalguide, Comment fonctionne le machine learning ?, 2019, <https://www.ionos.fr/digitalguide/web-marketing/analyse-web/quest-ce-que-lapprentissage-automatique/> , date de consultation 10/06/2021.
- [44] Machine Learnia, Machine Learning Archives, 2019, <https://machinelearnia.com/machine-learning/> , date de consultation : 16/06/2021.
- [45] Romain Cendre. Classification par les méthodes d'apprentissage supervisé et faiblement supervisé d'images multimodales pour l'aide au diagnostic du lentigo malin en dermatologie. Doctorat en Informatique. Université Bourgogne Franche-Comté, 2021.
- [46] Data Analytics Post, Apprentissage par renforcement, <https://dataanalyticspost.com/Lexique/apprentissage-par-renforcement/> date de consultation : 21/06/2021.

Bibliographie

- [47] Julie Lorenzini, Deep Learning VS Machine Learning, Le coin du digital, 2018, <https://www.le-coin-du-digital.com/index.php/2018/07/11/deep-learning-vs-machine-learning/> date de consultation : 21/06/2021
- [48] Natural solutions, Histoire du deeplearning, blog, <https://www.natural-solutions.eu/blog/histoire-du-deep-learning> la date de consultation : 21/06/2021.
- [49] Guillaume Saint-Cirgue, Apprendre le machine learning en une semaine, Machine Larnia, 2019.
- [50] Moncoachdata, Comprendre les réseaux de neurones, Page Web, 2019, <https://moncoachdata.com/blog/comprendre-les-reseaux-de-neurones/> date de consultation : 06/07/2021.
- [51] Steven Walczak, Narciso Cerpa, Artificial Neural Networks, Encyclopedia of Physical Science and Technology (Third Edition), edition Academic Press, ISBN 978-0-12-227410-7, 2001, p631-645.
- [52] Juri'Predis, Démystifier le Machine Learning, Partie 2 : les Réseaux de Neurones artificiels, Page Web, <https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-les-reseaux-de-neurones-artificiels> date de consultation : 18/07/2021
- [53] Claude Touzet. Les réseaux de neurones artificiels, introduction au connexionnisme : cours, exercices et travaux pratiques. EC2, Collection de l'EERIE, N. Giambiasi, 1992.
- [54] JDN, Perceptron : retour sur l'ancêtre du machine learning, Page Web, 2021, <https://www.journaldunet.fr/web-tech/guide-de-l-intelligence-artificielle/1501903-perceptron-retour-sur-l-ancetre-du-machine-learning/> date de consultation : 19/07/2021.
- [55] Kongakura, Le perceptron multicouches | Le perceptron multi-couches - Deeplearning, Page Web, 2019, <https://kongakura.fr/article/Le-perceptron-multicouches> date de consultation :19/07/2021
- [56] Marina Chane, Deeplearning : les réseaux de neurones convolutifs pour la classification d'images médicales, Page Web IMAIOS, 2021, <https://www.imaios.com/fr/Societe/blog/Classification-des-images-medicales-comprendre-le-reseau-de-neurones-convolutifs-CNN> date de consultation: 06/07/2021
- [57] Kamalika Some, The History, Evolution and Growth of Deep Learning, blog Analytics Insight, <https://www.analyticsinsight.net/the-history-evolution-and-growth-of-deep-learning/> date de consultation : 21/06/2021
- [58] Bernard Marr, A Short History Of Deep Learning -- Everyone Should Read, blog Bernard Marr&co, 2021, <https://bernardmarr.com/a-short-history-of-deep-learning-everyone-should-read/> date de consultation : 21/06/2021
- [59] Fouad Daoud, Farouk Louali, La Reconnaissance Des Caractères Arabes Manuscrits Par Les Réseaux Des Neurones Convolutionnels, Mémoire de Master en Informatique, Université Saad Dahleb-Blida, 2019.

Bibliographie

- [60] OpenClassrooms, Apprenez à construire un CNN et gagnez du temps avec le Transfer Learning, Page Web, <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5088816-apprenez-a-construire-un-cnn-et-gagnez-du-temps-avec-le-transfer-learning> date de consultation : 03/09/2021
- [61] IONOS Digitalguide, Quelles sont les différences entre le Deep learning et le Machine learning ?, Page Web, 2020, <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/deep-learning-vs-machine-learning/> date de consultation 21/07/2021.
- [62] Thomas B, Lina F, Gary B, Transfer Learning : Qu'est-ce que c'est?, Blog Formation Data Science | DataScientest.com, 2020, <https://datascientest.com/transfer-learning> date de consultation : 22/07/2021.
- [63] Moi Hoon Yap, Gerard Pons, Joan Marti, Sergi Ganau, Melcior Sentis, Reyer Zwiggelaar, Adrian K. Davison, Robert Martí, Automated Breast Ultrasound Lesions Detection Using Convolutional Neural Networks, IEEE Journal of Biomedical and Health Informatics, Vol 22, N°04, P1218-1226, 2018.
- [64] Seokmin Han, Ho-Kyung Kang, Ja-Yeon Jeong, Moon-Ho Park, Wonsik Kim, Won-Chul Bang, Yeong-Kyeong Seong, A deep learning framework for supporting the classification of breast lesions in ultrasound images, Physics in Medicine & Biology, Vol 62, n°19, p7714-7728, 2017.
- [65] Walid Al-Dhabyani, Aly Fahmy, Mohammed Gomaa, Hussien Khaled, Deep Learning Approaches for Data Augmentation and Classification of Breast Masses using Ultrasound Images, International Journal of Advanced Computer Science and Applications, Volume 10, n°5, p618-627, 2019, ISSN21565570, 2158107X
- [66] Chia-Yen Lee, Guan-Lin Chen, Zhong-Xuan Zhang, Yi-Hong Chou, Chih-Chung Hsu, Is Intensity Inhomogeneity Correction Useful for Classification of Breast Cancer in Sonograms Using Deep Neural Network? Journal of Healthcare Engineering, Volume 2018, p1-10, 2018, ISSN2040-2295, 2040-2309.
- [67] I. Cherifi. Apport de l'intelligence artificielle dans la détection du cancer du sein, mémoire de master en électronique, université de Blida 1, 2020.
- [68] N. Salem. Analyse profonde d'images ultrasonores pour la détection du cancer du sein, mémoire de master en électronique, université de Blida 1, 2020.
- [69] BUSI dataset. <https://scholar.cu.edu.eg/?q=afahmy/pages/dataset>, date de consultation, janvier 2021.
- [70] Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Doumghar, Pierre-Alain Muller, Augmentation de données pour la classification de séries temporelles par réseaux de neurones profonds résiduels, IRIMAS, Université de Haute-Alsace, 68100 Mulhouse, France, P375-376, 2018.

Bibliographie

[71] Eleonora Cagli, Cécile Dumas, Emmanuel Prouff. Convolutional Neural Networks with Data Augmentation against Jitter-Based Countermeasures. Cryptographic Hardware and Embedded Systems - CHES 2017 - 19th International Conference, Sep 2017, Taipei, Taiwan.

[72] Andrew Ng, Augmentation des données, Page Web, <https://fr.coursera.org/lecture/convolutional-neural-networks-fr/augmentation-des-donnees-AYzbX> date de consultation 17/08/2021.

[73] El Habib Benlahmer, Les réseaux de neurones convolutifs, Page Web DataScienceToday, <https://datasciencetoday.net/index.php/en-us/deep-learning/173-les-reseaux-de-neurones-convolutifs> date de consultation 06/07/2021.

[74] Gary B, Convolutional neural network | Deep Learning, Page Web DataScientest, 2020, <https://datascientest.com/convolutional-neural-network>, date de consultation : 26/07/2021.

[75] V. Thibault, VGG : en quoi consiste ce modèle ? Daniel vous dit tout ! Page Web DataScientist, 2021, <https://datascientest.com/quest-ce-que-le-modele-vgg> date de consultation : 20-08-2021.

[76] CSDN, Keras-VGG16, blog, 2019, <https://blog.csdn.net/u010986753/article/details/98777896> date de consultation : 22/08/2021.

[77] Keras-VGG19, Page Web, <https://blog.csdn.net/u010986753/article/details/98793695>, date de consultation : 22/08/2021.

[78] Sik-Ho Tsang, Review: GoogLeNet (Inception v1)— Winner of ILSVRC 2014 (Image Classification), Page Web Medium, 2018, <https://medium.com/coinmonks/paper-review-of-googlenet-inception-v1-winner-of-ilsvrc-2014-image-classification-c2b3565a64e7>, date de consultation:24/08/2021

[79] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015.

[80] Christian Szegedy, Zbigniew Wojna, Jonathon Shlens, Sergey Ioffe, Vincent Vanhoucke, Rethinking the Inception Architecture for Computer Vision, arXiv.org, arXiv:1512.00567 [cs], 2015.

[81] MichielStraat, On-line learning in neural networks with ReLU activations, Doctoraten Intelligent Systems, University of Groningen, <https://michielstraat.com/talk/mastertalk/>, 2018, date de consultation, 03/juillet/2021.

[82] Adam Milton-Barker, Inception V3 Deep Convolutional Architecture For Classifying Acute Myeloid/Lymphoblastic Leukemia, Page Web Intel, <https://www.intel.com/content/www/us/en/develop/articles/inception-v3-deep-convolutional-architecture-for-classifying-acute-myeloidlymphoblastic.html>, date de consultation 30/08/2021.

Bibliographie

[83] Sik-Ho Tsang, Review: Inception-v3 — 1st Runner Up (Image Classification) in ILSVRC 2015, Page Web Medium, 2018, <https://sh-tsang.medium.com/review-inception-v3-1st-runner-up-image-classification-in-ilsvrc-2015-17915421f77c> date de consultation 30/08/2021.

[84] Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, Alexander A. Alemi, Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17), p4278-4284,1600 Amphitheatre Parkway Mountain View, CA, US, 2017.

[85] Boughaba Mohammed, Boukhris Brahim, L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu, Master Professionnel en Informatique Fondamentale, UNIVERSITE KASDI MERBAH OUARGLA, 2017.

[86] Syed Abdul Gaffar Shakhadri, What is ResNet | Build ResNet from Scratch With Python, Blog Analytics Vidhya, 2021, <https://www.analyticsvidhya.com/blog/2021/06/build-resnet-from-scratch-with-python/> date de consultation: 31/08/2021.

[87] Priya Dwivedi, Understanding and Coding a ResNet in Keras, Blog Towards Data Science, 2019, <https://towardsdatascience.com/understanding-and-coding-a-resnet-in-keras-446d7ff84d33> date de consultation 31/08/2021.

[88] SinnoJialin Pan and Qiang Yang, A Survey on Transfer Learning, IEEE Transactions on Knowledge and Data Engineering, Volume 22, n°10, p1345-1359, 2010.

[89] Jason Brownlee, A Gentle Introduction to Transfer Learning for Deep Learning, Blog Machine Learning Mastery, 2017, <https://machinelearningmastery.com/transfer-learning-for-deep-learning/> date de consultation : 02/09/2021.

[90] OpenClassrooms, Apprenez à construire un CNN et gagnez du temps avec le Transfer Learning, Page Web, <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5088816-apprenez-a-construire-un-cnn-et-gagnez-du-temps-avec-le-transfer-learning> date de consultation : 03/09/2021.

[91] Mariane Chane, Deep learning en imagerie médicale : stratégies d'apprentissage pour les modèles, Page Web IMAIOS,2021, <https://www.imaios.com/fr/Societe/blog/IA-pour-l-imagerie-medicale-strategies-d-apprentissage> date de consultation : 04/09/2021.

[92] Futura Tech, Python: qu'est-ce que c'est ? Page Web, <https://www.futura-sciences.com/tech/definitions/informatique-python-19349/> date de consultation : 06/09/2021

[93] Editions Eni, Python pour la Data Science - Analysez vos données par la pratique avec NumPy, Pandas, Matplotlib et Seaborn - Qu'est-ce qu'Anaconda ?, Page Web, <https://www.editions-eni.fr/open/mediabook.aspx?idR=ce9dd3ca6c1dd8da7994634f80949fc6> date de consultation : 06/09/2021

Bibliographie

[94] Anaconda documentation, Anaconda Navigator, Catalogue de bibliographie, <https://docs.anaconda.com/anaconda/navigator/?highlight=anaconda%20navigator#anaconda-navigator> date de consultation : 06/09/2021.

[95] The Spyder Project Contributors, spyder: The Scientific Python DevelopmentEnvironment, Catalogue de bibliographie PyPI, <https://www.spyder-ide.org/> date de consultation : 07/09/2021.

[96] Bastien L, TensorFlow : tout savoir sur la bibliothèque Machine Learning open source, Blog LeBigData.fr,2018, <https://www.lebigdata.fr/tensorflow-definition-tout-savoir> date de consultation : 07/09/2021.

[97] Team Keras, Kerasdocumentation: About Keras, Page Web, <https://keras.io/about/> date de consultation : 08/09/2021.

[98] Laura P, NumPy : découvrez la bibliothèque Python la plus utilisée en Data Science, Blog DataScientest, 2021, <https://datascientest.com/numpy> date de consultation : 08/09/2021

[99] Thibault V, Scikit-Learn : Découvrez la librairie Python dédié au Machine Learning, Blog Formation Data Science | DataScientest.com, 2021, <https://datascientest.com/tout-savoir-sur-scikit-learn> date de consultation : 09/09/2021.

[100] Florian Fasmeyer, matplotlib, Documentation Bibliothèques Python 1.0.0, <https://he-arc.github.io/livre-python/matplotlib/index.html> date de consultation 09/09/2021.