

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE M'HAMED BOUGARA-BOUMERDES



Faculté de Technologie

Département Ingénierie des Systèmes Electriques

Mémoire de Master

Présenté par

Lemou Sara

Filière :Génie Biomédical

Spécialité :Instrumentation Biomédicale

Détection précoce de kératocône dans les images de la topographie cornéenne

Soutenu le 12 / 07 / 2021 devant le jury composé de:

Dr Messaoudi	Noureddine	MCA	UMBB	Président
Dr Belkacem	Samia	MCA	UMBB	Examinatrice
Dr AMMAR	Mohammed	MCA	UMBB	Encadreur
Dr Lazouni	Amine	MCA	UABB	Co-Encadreur

Année Universitaire : 2020/2021

REMERCIEMENTS

*Je remercie **DIEU** le tout puissant, qui m'a donné la force et la patience d'accomplir ce travail.*

Ce travail a été réalisé grâce à l'aide de nombreuses personnes que l'on voudrait remercier ici.

*Je tiens à exprimer mes sincères remerciements et ma profonde gratitude à mon promoteur **Mr. AMMAR Mohammed** pour sa disponibilité, ses conseils, ses encouragements et pour son aide précieuse qui m'a permis d'aboutir à l'achèvement de ce travail.*

*Ensuite Je tiens à remercier **Monsieur Lazouni Mohammed El Amine** maitre de conférences A. Au département de génie biomédical à l'Université d'Abou Bakr Belkaïd de Tlemcen, pour son professionnalisme et ses remarques pertinentes. Et de m'avoir fait l'honneur d'être membre de ce travail.*

*Monsieur, **Messaoudi Noureddine** maitre de conférences A. Au département d'Ingénierie des Systèmes Electriques de l'Université M'Hamed Bougara, de nous avoir fait l'honneur de présider ce jury.*

*Madame **Belkacem Samia** maitre de conférences A. Au département de génie électrique de l'Université M'Hamed Bougara, de nous avoir fait l'honneur d'être membre de ce jury et d'examiner ce travail.*

*Monsieur **Chikhaoui Soufiane**, Docteur en Médecine Biophysique à l'Hôpital de Tenia Boumerdes, pour sa présence, ses conseils et le dynamisme qu'il a su m'inspirer, et pour m'avoir intégré et facilité la réalisation de ce modeste travail. Trouve mes sincères remerciements.*

***La Clinique Lazouni**, et **Dr Lazouni** Médecin spécialiste en ophtalmologie, qui nous a ouvert les portes de sa clinique, à Tlemcen. Trouvent ici mes sincères remerciements.*

Enfin, que tous ceux qui ont participé de près ou de loin à la réalisation de ce travail, en particulier l'ensemble des enseignants qui sont à l'origine de tout notre savoir, soient remerciés.

Dédicaces

Je dédie ce travail aux deux êtres les plus chères au monde, les bougies qui m'ont toujours guidé vers le bon chemin :

Mon père et ma mère qui n'ont jamais cessé de m'encourager. Tous les mots du monde ne sauraient exprimer l'immense amour que je vous porte, ni la profonde gratitude que je vous témoigne.

A mes chers frères Amine, et Abed-el Madjid et a mes chers sœurs Amel, Wahiba, Kahina et Akila qui m'ont encouragé sans cesse et cru en moi.

À mes chers petits neveux et nièces.

Et à toute ma famille.

A mes chers amis : Amel, Souhila, wassila, Amina, Fatouma, Sabah, Samia et Lydia; pour leurs appuis et leurs encouragements.

A mes amies et mes collègues de l'université de Boumerdes.

Enfin, que tous ceux qui m'ont aidés et encouragés de près ou de loin dans la concrétisation de ce projet, trouvent ici ma gratitude et mes sincères remerciements.

Résumé

Le kératocône est une maladie oculaire qui affecte directement la cornée. Le but de ce travail est d'aider la détection précoce du kératocône, Nous avons utilisé deux modèles: CNN simple et le modèle Alexnet.

Nous avons utilisé une base de données locale constituée de 274 patients.

Nous avons testé deux architectures, l'une basée sur CNN et la seconde basée sur le modèle Alexnet avec les algorithmes d'apprentissage « Adam, Rmsprop, et Sgdm ».

Les résultats obtenus ont montré que le modèle Alexnet avec l'algorithme "Rmsprop" donne le meilleur TC= 95,6%, par contre le modèle CNN avec la fonction SGDM donne la meilleure sensibilité (92.1%).

Mots-clés: Kératocône (KC), Classification, Apprentissage Profond(DL), CNNs, Alexnet, RMsprop.

Abstract

Keratoconus is an ocular disease that directly affects the cornea. The aim of this work is to help the early detection of keratoconus. We used two models: simple CNN and the Alexnet model.

We used a local database consisting of 274 patients.

We tested two architectures, one based on CNN and the second based on the AlexNet model with the learning algorithms "Adam, Rmsprop, and Sgdm".

The results obtained showed that the Alexnet model with the "Rmsprop" algorithm gives the best TC= 95.6%, on the other hand the CNN model with the SGDM function gives the best sensitivity (92.1%).

Keywords: Keratoconus (KC), Classification, Deep Learning (DL), CNNs, Alexnet, RMsprop.

ملخص

القرنية المخروطية مرض يصيب العين ويصيب القرنية مباشرة. الغرض من هذا العمل هو المساعدة في الكشف المبكر عن القرنية المخروطية، استخدمنا نموذجين: نموذج CNN البسيط ونموذج Alexnet. استخدمنا قاعدة بيانات محلية لـ 274 مريضاً.

اختبرنا هيكليين، أحدهما يعتمد على CNN والآخر يعتمد على نموذج AlexNet باستخدام خوارزميات التعلم "Adam و Rmsprop و Sgdm".

أظهرت النتائج التي تم الحصول عليها أن نموذج Alexnet مع خوارزمية "Rmsprop" يعطي أفضل $TC = 95.6\%$ ، ومن ناحية أخرى فإن نموذج CNN المزود بوظيفة SGDM يعطي أفضل حساسية (92.1%).

الكلمات المفتاحية: القرنية المخروطية، التصنيف، التعلم العميق، CNNs، Alexnet، RMsprop.

TABLE DES MATIERES

Table des matières

REMERCIEMENTS	i
DEDICACES	ii
RESUME	iii
TABLE DES MATIERES	iv
LISTE DES FIGURES	xiii
LISTE DES TABLEAUX	x
LISTE DES ABREVIATIONS	xi
INTRODUCTION GENERALE	1
I.1 Contexte	1
I.2 Problématique	2
I.3 Contribution	2
I.4 Organisation du manuscrit	3
CHAPITRE I: GENERALITES SUR L'OEIL	5
I.1 Introduction	5
I.2 Anatomie de la cornée	5
I.2.1 Anatomie macroscopique de la cornée.....	5
I.2.1.1 Le film lacrymal pré-corné	6
I.2.1.2 L'épithélium cornéen.....	6
I.2.1.3 Le stroma cornéen	6
I.2.1.4 La membrane de Descemet.....	6
I.2.1.5 L'endothélium cornéen.....	7
I.3 Épidémiologie	7
I.4 Etiologies	8
I.5 Symptômes	9
I.6 Evolution	9
I.6.1 Classification et stades du kératocône.....	9
I.7 Le diagnostic	12
I.7.1 La topographie cornéenne	13
I.7.1.1 Définition.....	13

I.7.1.2	Intérêt de la topographie cornéenne.....	13
I.7.1.2.1	La topographie spéculaire.....	13
I.7.1.2.2	La topographie d'élévation.....	14
I.7.1.3	Principes de fonctionnement	14
I.7.1.4	Les Cartes de topographie cornéenne.....	15
I.8	Traitement du kératocône	16
I.9	Conclusion.....	17
CHAPITRE II: CLASSIFICATION D'IMAGES PAR CNNS		19
II.1	Introduction	19
II.2	Machine Learning	20
II.2.1	Définition	20
II.3	Deep Learning.....	20
II.4	Machine Learning vs Deep Learning	22
II.5	Critères de choix entre le Deep Learning et le Machine Learning	22
II.6	Classification d'images par Deep Learning	22
II.6.1	L'infographie et les images.....	22
II.6.1.1	Définition d'image.....	22
II.6.1.2	Caractéristiques d'une image	23
II.6.1.2.1	Définition.....	23
II.6.1.2.2	Résolution.....	23
II.6.1.2.3	Taille d'une image	23
II.6.1.3	Différents types d'images.....	23
II.6.1.3.1	Image RVB	23
II.6.1.3.2	Image d'intensités.....	24
II.6.1.3.3	Image binaire	24
II.6.1.4	Codage d'images numériques.....	24
II.6.1.5	La numérisation	25
II.6.2	Classification des images.....	25
II.7	Les méthodes de classification	26
II.7.1	Méthodes non supervisées	26
II.7.2	Méthodes supervisées	26
II.7.3	Présentation de certaines techniques de la classification.....	26
II.7.3.1	Le classifieur K-plus proche voisin.....	26
II.7.3.2	Le classifieur SVM.....	27
II.7.3.3	Les réseaux de neurones artificiels (RNA).....	27
II.7.3.3.1	Modélisation d'un neurone : une inspiration biologique.....	27
II.7.3.3.2	Quelle est le lien entre les neurones biologiques et neurones artificiels?	28
II.7.3.3.3	Principe des réseaux de neurones	29
II.7.3.3.4	Typologie des réseaux neuronaux	29
II.7.3.4	Réseaux Neurones Convolutionnels (CNN).....	31
II.7.3.5	Avantages du CNN par rapport au MLP	31
II.8	Réseaux de Neurones Convolutifs (CNNs)	31

II.8.1 Principe d'architecture d'un CNN	31
II.8.2 La convolution	32
II.8.3 Architecture de réseaux de neurones convolutionnels.....	32
II.8.3.1 Couches convolutionnelles	33
II.8.3.2 Couches de pooling	33
II.8.3.3 Couches entièrement connectées	34
II.8.4 Fonctionnement d'un réseau de neurones convolutifs.....	34
II.8.4.1 Couche de convolution	34
II.8.4.2 Unités linéaires rectifiées (ReLU)	35
II.8.4.3 La couche de pooling.....	35
II.8.4.4 Couche entièrement connectée	37
II.8.4.5 L'entraînement d'un réseau de neurone convolutionnelle	37
II.8.5 Exemples d'architectures	38
II.8.5.1 Alexnet	38
II.8.5.1.1 Architecture du modèle 01 (AlexNet)	38
II.8.5.2 ResNet	39
II.8.5.3 LeNet-5.....	40
II.8.5.4 ZFNet.....	40
II.8.5.5 VGGNet.....	41
II.8.5.6 GoogLeNet	41
II.9 Indicateurs de performance en classification.....	42
II.9.1.1 Perte logarithmique	42
II.10 Conclusion	43
CHAPITRE III: IMPLEMENTATION, RESULTATS ET DISCUSSIONS	45
III.1 Introduction	45
III.2 Problématique étudiée.....	45
III.3 Configuration utilisé dans l'implémentation	45
III.3.1 Ordinateur	45
III.3.2 Langage de programmation	45
III.3.3 Présentation de la base de données.....	46
III.3.3.1 Exemples des images contenues dans la BDD (BDD images).....	47
III.4 Pré traitement des données.....	48
Chargement des données	49
III.5 Architecture de notre réseau	49
Métriques d'évaluation	50
III.5.1.1 Rappel ou sensibilité ou TPR (True Positive Rate).....	50
III.5.1.2 Spécificité ou TNR (True Negative Rate)	50
III.5.1.3 Précision	51
III.5.2 Matrice de confusion	51
III.6 Entraînement du modèle.....	51
III.7 Résultat du modèle 01 (CNN).....	52
III.7.1 Discussion.....	62

III.8	Résultat du modèle 02 (ALEXNET)	63
III.8.1	Formation, Validation, Résultats et discussions	63
III.9	comparaison des résultats	68
III.10	Conclusion	69
	CONCLUSION GENERALE	71
	BIBLIOGRAPHIE	73

LISTE DES FIGURES

Liste des figures

FIGURE I.1. Coupe sagittale schematique de l'œil montrant les differents rapports de la cornee.	5
FIGURE I.2. Les couches principaleux de la corne	7
FIGURE I.3. Deformation conique de la cornee caracteristique du keratocone.....	8
FIGURE I.4. Classification du kc d'apres Amsler- Krumeich.	10
FIGURE I.5. La classification Belin ABCD du kc	11
FIGURE I.6. Differents aspects topographiques a partir de cartes axiales en echelle absolue. D'apres (Matalia and Swarup 2013)	11
FIGURE I.7. Indices en topographie speculaire permettant de distinguer les kc infracliniques des kc averes	12
FIGURE I.8. Indices en topographie d'elevation sur la carte pachymetrique des cas suspects de kc	12
FIGURE I.9. Images obtenues en topographie speculaire en utilisant le disque dePlacido	13
FIGURE I.10. Topographe ORBSCAN II.	14
FIGURE I.11. Carte topographique d'un cas pathologique.....	15
FIGURE II.1. Les differents algorithmes de Machine Learning	20
FIGURE II.2. La relation entre l'IA, ML et DL	21
FIGURE II.3. ML vs DL.....	21
FIGURE II.4. Representation dune image RVB	23
FIGURE II.5. Representation dune image ou niveaux de gris	24
FIGURE II.6. Representation dune image binaire	24
FIGURE II.7. Schemas d'un neurone biologique.....	28
FIGURE II.8. Le neurone biologique et le neurone artificiel.	28
FIGURE II.9. Presentation d'un neurone formel.....	30
FIGURE II.10. Architecture d'un perceptron multicouche	30
FIGURE II.11. Architecture d'un reseau de neurones convolutifs	32
FIGURE II.12. Operation d'une convolution sur image de 5*5pixel.....	33
FIGURE II.13. Fonction RELU	35
FIGURE II.14. Max-Poolingavec un filtre 2x2 et un pas de 2	36
FIGURE II.15. Mise en commun appliquee aux cartes de fonctions rectifiees	36
FIGURE II.16. Architecture d'AlexNeT	38
FIGURE II.17. Architecture de ResNeT.....	39
FIGURE II.18. Architecture LeNeT	40
FIGURE II.19. Architecture ZFNET	40
FIGURE II.20. Architecture VGGNeT.....	41
FIGURE II.21. Architecture GoogleNeT	42
FIGURE III.1. Interface MATLAB.....	46
FIGURE III.2. Histogramme de statistiques du KERATOCONE	47
FIGURE III .3. Carte topographique de l'œil gouache d'un cas normal	48
FIGURE III.4. Carte topographique d'un cas atteint du keratocone.....	48
FIGURE III .5. Matrice de confusion	51
FIGURE III.6. Apprentissage par la fonction ADAM pour MaxEpochs=10.....	52
FIGURE III.7. Apprentissage par la fonction SGDM pour MaxEpochs=10	52
FIGURE III.8. Apprentissage par la fonction RMSPROP pour MaxEpochs=10.....	53
FIGURE III .9. Apprentissage par la fonction ADAM pour MaxEpochs=20.....	53
FIGURE III .10. Apprentissage par la fonction SGDM pour MaxEpochs=20	54

FIGURE III.11. Apprentissage par la fonction RMSPROP pour MaxEpochs=20.....	54
FIGURE III .12. Apprentissage par la fonction ADAM pour MaxEpochs=30.....	55
FIGURE III .13. Apprentissage par la fonction SGDM pour MaxEpochs=30	55
FIGURE III.14. Apprentissage par la fonction RMSPROP pour MaxEpochs=30.....	56
FIGURE III .15. Apprentissage par la fonction ADAM pour MaxEpochs=10.....	56
FIGURE III.16. Apprentissage par la fonction SGDM pour MaxEpochs=10	57
FIGURE III .17. Apprentissage par la fonction RMSPROP pour MaxEpochs=10.....	57
FIGURE III .18. Apprentissage par la fonction ADAM pour MaxEpochs=10.....	58
FIGURE III.19. Apprentissage par la fonction SGDM pour MmaxEpochs=10	58
FIGURE III.20. Apprentissage par la fonction RMSPROP pour MaxEpochs=10.....	59
FIGURE III.21. Apprentissage par la fonction SGDM option pour MaxEpochs=10	64
FIGURE III.22. Apprentissage par la fonction ADAM option pour MaxEpochs=10.....	64
FIGURE III.23. Apprentissage par la fonction RMSPROP option pour MaxEpochs=10	65
FIGURE III.24. Matrice de confusion obtenue par la fonction RMSPROP pour MaxEpochs=10.....	65
FIGURE III .25. Matrice de confusion obtenue par la fonction ADAM pour MaxEpochs=10	66
FIGURE III .26. Matrice de confusion obtenue par la fonction SGDM pour MaxEpochs=10	66

LISTE DES TABLEAUX

Liste des tableaux

Tableau III:1	Repartition des patients dans la BDD.....	46
Tableau III:2	Decoupage de bases de donnees la BDD	49
Tableau III:3	Tableau comparatif des resultats obtenus pour Batchsize=16.....	60
Tableau III:4	Tableau comparatif des resultats obtenus pour Batchsize=32.....	61
Tableau III:5	Tableau comparatif des resultats obtenus pour Batchsize=64.....	62
Tableau III:6	Tableau comparatif des resultats obtenus pour Batchsize=16.....	67
Tableau III:7	Tableau de comparaison de resultats	68

LISTE DES ABRÉVIATIONS

Liste des abréviations

- ACC:** Accuracy
- Adagrad:** Gradient Adaptatif
- Adam:** Adaptive Moment Estimation
- BDD :** Base De Données
- BFS:** Best Fit Sphere
- CLEK:** Collaborative Longitudinal Evaluation Of Keratoconus
- CMYK (CMJN) :** Combinaison De Pigments Colorés , (Cyan, Magenta, Jaune)
- CNN:** Convolutional Neural Networks
- CXL:** Cross-Linking Du Collagène Cornéen,
- DL:** Deep Learning
- DPI:** Dots Per Inch
- FC:** Fully Connected
- FP:** Faux Positif
- GAN:** Generative Adversal Networks
- HLS (TLS):** Teinte, Luminance, Saturation
- IA:** Intelligence Artificielle
- JPEG:** Joint Photographic Experts Group
- KCN (KC):** Kératocône
- Kmax:** Kératométrie Maximum
- LASIK:** LASER In SITUE Tu Keratomileusis
- Log Loss:** Perte Logarithmique
- Maps:** Cartes De Convolution
- MATLAB:** Matrix Laboratory
- ML:** Machine Learning
- MLP:** Perceptron Multicouche
- OG:** Œil Gauche
- PKR (PRK):** Photorefractive Keratectomy
- PPP:** Point Par Pouces
- Relu:** Unités Rectifié Linéaires

Resnet: Réseau Neuronal Résiduel
RGB: Rouge, Vert, Bleu
Rmsprop:Root Mean Square Propagation
RNA: Réseaux De Neurones Artificiels
SGDM: Stochastic Gradient Descent With Momentum
SVM:Support Vector Machine
TC :Taux De Classification
TN:True Negative
TNR:True Negative Rate
TP:True Positive
TPR: True Positive Rate
VN : Vrai Négatif
VP : Vrai Positif
VPN: négative prédictive
XOR: Fonction Ou Exclusif

INTRODUCTION GÉNÉRALE

Introduction générale

I.1 CONTEXTE

Le système visuel de l'être humain est l'un des systèmes les plus développés ; il est extraordinaire par la quantité et la qualité des informations qu'il nous fournit sur le monde. Un rapide coup d'œil suffit pour connaître la position, la taille, la forme, la couleur et la texture des objets, soit qu'ils sont en place ou en déplacement (leur direction et leur vitesse relative). Le stimulus de l'œil est la lumière, Les récepteurs de cette lumière sont les photorécepteurs de la rétine qui est un tissu neuronal qui recouvre le fond de l'œil [1].

Des petites faiblesses de la vue peuvent être très gênantes dans la vie quotidienne; dans certaines circonstances elles représentent même un danger. A côté des amétropies connues il y a le kératocône.

Le kératocône (KCN) est un trouble ectasique cornéen bilatéral progressif. Il se manifeste par une pentification caractéristique de la cornée en forme de cône associée à un amincissement irrégulier du stroma, entraînant un renflement en forme de cône (saillie) et une perte de vision significative [2].

Cette maladie est détectée en effectuant un examen de topographie cornéenne qui permet non seulement un meilleur diagnostic, en plus un outil d'aide aux médecins ophtalmologues dans la prise de décision précoce pour une meilleure prise en charge du patient.

Depuis plus de trois décennies plusieurs travaux ont été réalisés dans le domaine d'ophtalmologie plus exactement sur la cornée.

Nous citons le travail Bo-I Kuo, Wen-Yi Chang et al en 2020, intitulé « Keratoconus Screening Based on Deep Learning Approach of Corneal Topography », il ont développé et comparé des algorithmes d'apprentissage en profondeur (DL) où ils ont adopté trois modèles des réseaux de neurones convolutifs (VGG16, InceptionV3, et ResNet152) pour détecter le kératocône. La base de données collectée contient des images topographiques : 170 cas de kératocônes, 28 cas kératocônes infra cliniques et 156 cas normaux. La sensibilité et la spécificité de tous les modèles CNN étaient supérieures à 0,90 % [3].

Un autre travail proposé par d'Alexandru Lavric et al intitulé « Keratoconus Detection Algorithm using Convolutional Neural Networks: Challenges », en 2019, dont l'objectif principal était de mettre en œuvre un algorithme qui permet la détection du kératocône en facilitant le processus de diagnostic. En optimisant les paramètres associés au réseau de

neurones convolutifs, la précision de l'algorithme proposé a été augmentée à 99,33% pour l'ensemble de test [4].

Le dépistage du kératocône dans sa forme infra-clinique est un enjeu majeur en chirurgie réfractive, car il constitue une contre-indication formelle au LASIK, en raison du risque majeur d'une ectasie iatrogène. La prévalence du kératocône infra-clinique parmi les patients demandeurs de chirurgie réfractive est certainement plus élevée que dans la population générale. Le dépistage automatisé du kératocône infra-clinique est un enjeu de Santé publique [5].

I.2 PROBLEMATIQUE

Le kératocône est une affection dont l'origine est inconnue, même si certains de ses facteurs de risque ont été identifiés. Il est difficile d'estimer la prévalence des formes cliniquement silencieuses de kératocône, pour une raison qui est intrinsèque au problème soulevé par leur dépistage: il existe en effet un continuum topographique entre les cornées "saines" et celles atteintes d'une forme avérée de kératocône. Quel que soit le critère étudié, il existe un chevauchement significatif entre les formes débutantes de kératocône et certaines atypies cornéennes non évolutives.

L'absence de critères cliniques ou topographiques formels pour effectuer le diagnostic de kératocône débutant implique le recueil d'un large faisceau d'arguments cliniques et paracliniques, idéalement assortis d'un suivi dans le temps. Cette situation est compliquée par une profusion de termes souvent employés de manière interchangeable pour désigner les formes précoces de kératocône : kératocône fruste, forme suspecte de kératocône, kératocône débutant... Nous préférons les regrouper sous une même dénomination en les englobant sous le terme de "kératocône infraclinique débutant" [6].

Nous proposons dans ce travail d'améliorer la détection de kératocône à partir des paramètres numériques, et des images des cartes topographiques qui sont fourni par le topographe Orbscan II.

Pour parvenir à un tel résultat, un slogan est scandé « L'IA (Intelligence Artificielle) pour sauver des vies ». Les avancés de l'IA sont vouées à bouleverser le monde de la santé, et plus particulièrement sa branche du Deep Learning qui permet entre autres à partir de données radiologiques massives de développer des algorithmes de traitement, détection, classification et segmentation d'images médicales [7].

I.3 CONTRIBUTION

Les contributions de ce travail sont les suivantes :

- Utilisation et validation des résultats sur une base de données (BDD) locale collectée au niveau de la clinique LAZOUNI lors de la réalisation des examens de topographie cornéenne.
- Implémentation de deux modèles de CNN avec une comparaison entre les algorithmes d'apprentissage (ADAM, SGDM, RMSPROP).

I.4 ORGANISATION DU MANUSCRIT

Ce projet de fin d'étude est organisé de la manière suivante :

- Introduction générale
- Chapitre 1 : constitue une mise en contexte. Il fournit les éléments utiles à la compréhension du sujet de ce mémoire : kératocône (KC) ; définition, les symptômes, l'évolution, les examens cornéo-topographiques permettant l'acquisition des images en couleurs et les paramètres numériques ainsi que les traitements éventuels.
- Chapitre 2 : dans ce chapitre nous présentons les principes des outils implémentés dans le chapitre 3, D'autre part nous décrivons les différentes méthodes de traitement, classification, utilisées dans ce domaine. nous présenterons le Machine Learning (ML), ses domaines d'utilisation, ses approches et ses différents algorithmes. Nous nous intéresserons ensuite, au Deep Learning (DL) et plus particulièrement aux réseaux de neurones convolutifs CNNs pour la conception des systèmes de prédiction et de diagnostic médical. Nous verrons à la fin de ce chapitre les architectures les plus courantes des CNNs et quelques métriques de leur évaluation.
- Chapitre 3 : il est dédié à la détection du kératocône. Nous présentons une description de notre propre base de données qui contient 2267 images et les résultats d'implémentations des deux modèles CNN avec les trois algorithmes d'apprentissage.
- Finalement, Ce manuscrit sera clôturé par une conclusion générale en discutant des principaux résultats obtenus et présentant quelques perspectives s'inscrivant dans la continuité de ce travail de recherche.

CHAPITRE I

GENERALITES SUR L'OEIL

CHAPITRE I: GENERALITES SUR L'OEIL

I.1 INTRODUCTION

Le kératocône est une maladie cornéenne dégénérative se manifestant par une protrusion non inflammatoire et un amincissement de la cornée dans sa région axiale, donnant à la cornée l'aspect de cône. Il entraîne une diminution de l'acuité visuelle du fait de la survenue de myopie et d'astigmatisme irrégulier ainsi que l'apparition d'opacités cornéennes à un stade avancé. L'origine de cette maladie est multifactorielle et le facteur de risque le plus impliqué dans sa pathogénie est le frottement des yeux. Toutefois, une composante génétique est irréfutable [8].

Dans ce chapitre, nous allons développer le thème de cette recherche qui consiste à définir la description générale de la maladie ainsi que l'atteinte histologique au niveau de la cornée et citer les causes lui donnant naissance ainsi que son évolution. Nous allons clôturer ce chapitre en énumérant les types de topographies et les traitements adéquats.

I.2 ANATOMIE DE LA CORNEE

I.2.1 Anatomie macroscopique de la cornée

La cornée est le principal élément réfractif de l'œil. Elle couvre environ un cinquième de sa circonférence. Elle est avasculaire, transparente et enchâssée dans l'orifice antérieur de la sclérotique. La cornée répond en avant au film lacrymal et aux paupières, en arrière à la chambre antérieure. En périphérie, elle répond au limbe cornéoscléral (Figure I : 1).

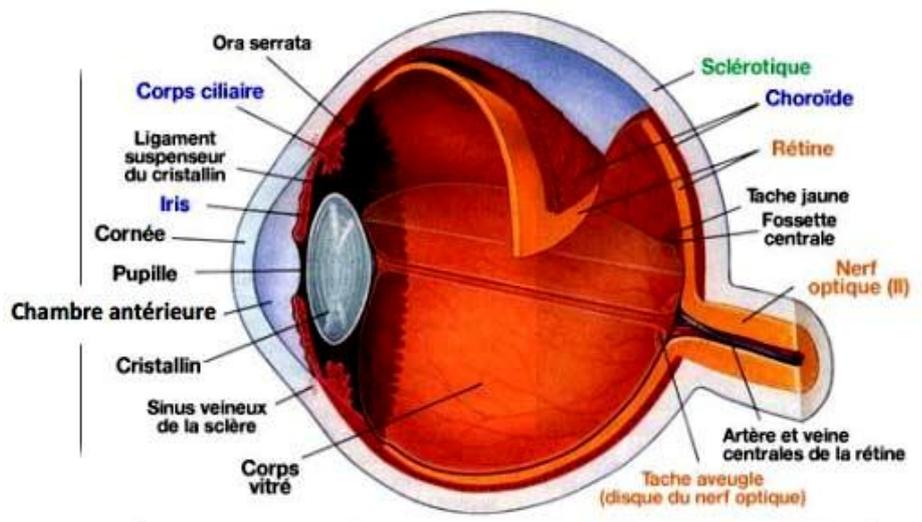


Figure I.1. Coupe sagittale schématique de l'œil montrant les différents rapports de la cornée.

La cornée est classiquement décrite en cinq couches, alors que son rôle réfractif impose d'inclure le film lacrymal dans sa structure normale.

I.2.1.1 Le film lacrymal pré-corné

Mesure 7 à 8 micromètres d'épaisseur, composé d'une couche profonde mucinique, intermédiaire aqueuse et externe lipidique. Il tapisse la surface externe cornéenne, la protège contre la dessiccation et participe à la régularité de l'épithélium.

I.2.1.2 L'épithélium cornéen

C'est un épithélium pavimenteux, poly stratifié (7 à 8 couches), non kératinisé, d'environ 50 microns d'épaisseur, qu'on peut décrire en 3 couches :

- Assise superficielle, faite de 2 ou 3 couches cellulaires d'autant plus minces qu'elles sont antérieures.
- Assise intermédiaire : 2 à 3 couches cellulaires.
- Assise basale unistratifiée, composée de cellules cubiques reposant sur une membrane basale adhérant fortement à la membrane de Bowman par des microfibrilles d'ancrage.

I.2.1.3 Le stroma cornéen

Représente la majeure partie de l'épaisseur cornéenne, soit environ 450 μm , avasculaire, paucicellulaire avec moins de 2 ou 3 % du volume en cellules. Il est constitué de collagène type I (75%) et accessoirement de collagène type V et VI. Le diamètre constant de 35 nm et l'espacement constant de 41 nm des fibrilles de collagène, à l'intérieur des fibres de collagène, ainsi que l'arrangement des fibres en lamelles parallèles entrelacées et reliées par des ponts inter lamellaires, sont indispensables à la transparence cornéenne. C'est le collagène du stroma qui assure l'essentiel de la résistance biomécanique de la cornée, maintenant sa forme contre les forces qui s'exercent sur elle (pression intraoculaire en arrière et paupières et pression atmosphérique en avant).

I.2.1.4 La membrane de Descemet

C'est une membrane amorphe, élastique et résistante, faite de fibrilles de collagène de petit diamètre réparties au sein d'une matrice glycoprotéique.

I.2.1.5 L'endothélium cornéen

Il se situe sur la face postérieure de la cornée. Il est constitué d'une monocouche de 5µm d'épaisseur. Les cellules endothéliales sont hexagonales et reposent sur la membrane de Descemet. Elles sont unies entre elles par des jonctions serrées à la partie apicale de l'espace intercellulaire et par des jonctions communicantes au niveau des membranes latérales [9].

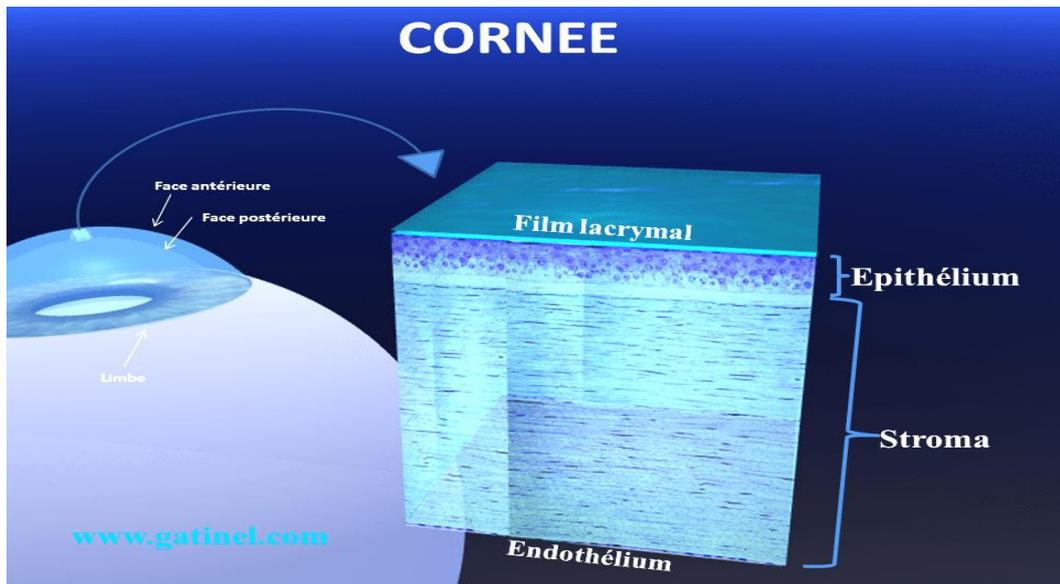


Figure I.2. Les couches principaux de la corne [13].

I.3 ÉPIDEMIOLOGIE

Le mot kératocône, d'origine grecque, signifie «cornée conique », Le kératocône est une maladie dégénérative de l'œil [10].

L'incidence est estimée à environ 1/2000 et la prévalence à 54/100 000 dans les populations caucasiennes européennes. Ces chiffres sont très variables d'un pays à l'autre et selon les critères diagnostiques utilisés par les auteurs. Mais ils sont probablement sous-estimés en raison des formes de kératocône fruste, non comptabilisées.

Ces formes « infra-cliniques » sont dépistées le plus souvent parmi les patients candidats à la chirurgie réfractive, lors du bilan systématique préopératoire comportant une topographie cornéenne. Parmi cette population, la fréquence de la maladie est de l'ordre de 0,9% et peut atteindre jusqu'à 8% dans une population de patients myopes. Le kératocône touche les deux sexes de manière équivalente.

Cette maladie touche toutes les races. L'incidence est plus élevée chez les asiatiques par rapport aux caucasiens (7,5 :1). Une incidence plus élevée a été rapportée dans une population rurale en Inde et en Arabie Saoudite. L'influence de la consanguinité et des formes familiales a été évoquée pour expliquer cette incidence plus importante.

Classiquement, le kératocône apparaît à la puberté et évolue jusqu'à la troisième ou quatrième décennie. Plus rarement, on observe des formes cliniques plus tardives ou plus précoces (forme congénitale). Sur une série multicentrique de 1579 patients, l'étude CLEK (pour Collaborative Longitudinal Evaluation of Keratoconus) rapporte un âge moyen de découverte de $27,3 \pm 9,5$ ans, avec près de 90 % des patients diagnostiqués entre 10 et 39 ans . Cependant l'âge de début de la maladie est probablement surestimé étant donné son caractère initialement asymptomatique.

De plus, l'âge de découverte dépend au moins en partie de la rapidité d'évolution de la maladie, très variable d'un patient à l'autre. En effet, le kératocône est évolutif dans environ 22% des cas et la vitesse de progression est maximale pendant la première décennie, ralentie pendant la deuxième et rare après 30 ans .



Figure I.3.Déformation conique de la cornée caractéristique du kératocône.

I.4 ETIOLOGIES

L'étiologie exacte du kératocône reste encore inconnue. Son association avec d'autres pathologies fait évoquer une origine multifactorielle: génétique, environnementale, métabolique. Les cas de kératocônes familiaux (6 à 23,5% des cas) attestent d'un rôle génétique dans l'apparition de cette maladie qui aurait un mode de transmission autosomique dominant à pénétrance et expressivité variables. Une transmission sur le mode autosomique récessif a été proposée dans les populations à forte consanguinité.

Les principaux facteurs associés sont: l'atopie, l'hérédité, les anomalies chromosomiques, les altérations du tissu conjonctif et les contraintes mécaniques [11].

I.5 SYMPTOMES

Les symptômes du kératocône vont généralement apparaître vers la fin de l'adolescence ou au début de la vingtaine, mais peuvent tout de même apparaître à n'importe quel moment. Le kératocône va parfois provoquer des troubles de la vision de nuit, en raison des halos et des éblouissements.

Les premiers signes typiques de kératocône sont :

- Vision floue.
- Besoin fréquent de changer une prescription.
- Vision floue qui ne se corrige pas avec les lunettes.
- Sensibilité à la lumière accrue.
- Difficulté à conduire la nuit.
- Halos et éblouissements, surtout la nuit.
- Fatigue visuelle.
- Maux de tête et douleur générale aux yeux.
- Irritation aux yeux [12].

I.6 EVOLUTION

Le kératocône, souvent découvert à la puberté, évolue généralement jusqu'à l'âge de 30-40 ans avant de se stabiliser. L'évolution est irrégulière, certains kératocônes restant stables pendant quelques années, d'autres s'aggravant puis se stabilisant à nouveau. Les kératocônes peuvent arrêter de progresser à n'importe quel stade. Les stades d'évolution peuvent être classés selon différents critères [13].

I.6.1 Classification et stades du kératocône

Plusieurs classifications faisant intervenir différents paramètres morphologiques du KC sont disponibles. Il n'existe cependant pas de consensus international. A l'issue de l'examen clinique. Le KC peut être classé en 4 stades selon la classification d'AMSLER (Figure I :4) :

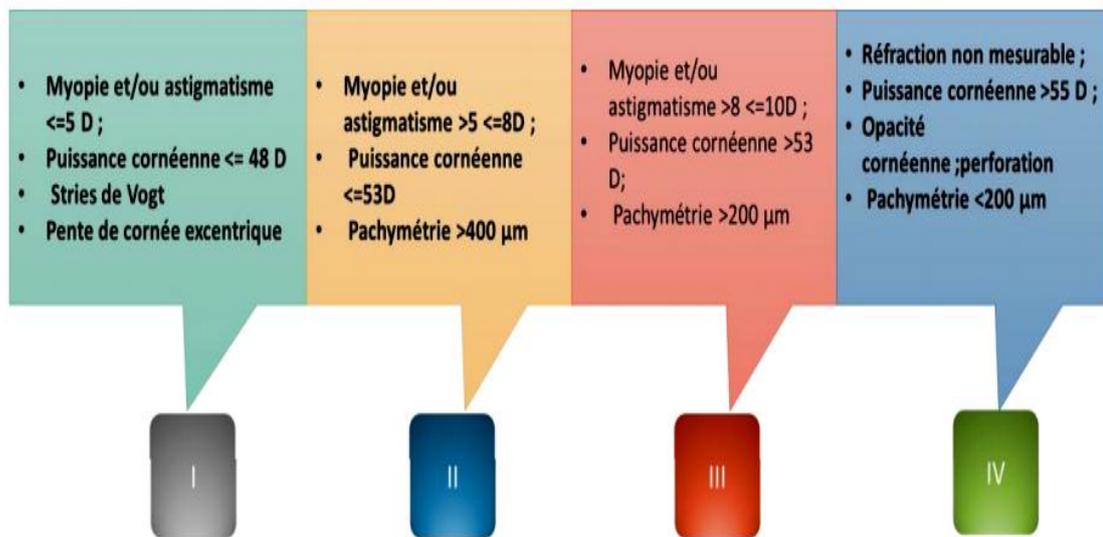


Figure I.4. Classification du KC d'après Amsler- Krumeich [14].

- **Il existe aussi la classification clinique de Krumeich (Figure I :4)**
- **Stade 1** : myopie et/ou astigmatisme < 48 Dioptries ; Stries de Vogt
- **Stade 2** : Myopie et/ou astigmatisme >5 $400 \mu\text{m}$
- **Stade 3** : Myopie et/ou astigmatisme >8 53 dioptries ; Pachymétrie $>200 \mu\text{m}$
- **Stade 4** : Réfraction non mesurable ; Puissance cornéenne >55 dioptries ; Opacité cornéenne ; Pachymétrie $< 200 \mu\text{m}$

- **La classification de BELIN ABCD (Figure I :5)**

Qui tient compte des données de la face postérieure de la cornée. Cette classification a pour avantage d'être intégrée directement dans la plateforme Pentacam. Celle-ci inclut des données tomographiques telles que le rayon de courbure antérieur et postérieur des 3 mm autour du point le plus fin, la pachymétrie (épaisseur de la cornée) minimale, mais également l'acuité visuelle mesurée. Elle permet ainsi de manière automatisée de documenter les modifications significatives et d'évaluer l'efficacité d'un traitement tel que le « cross-linking ».



Figure I.5.La classification Belin ABCD du KC

Les critères ABCD comprennent : A (Rayon de courbure antérieur), B (rayon de courbure postérieur), C (pachymétrie), D (meilleure acuité visuelle corrigée) Grâce aux développements des méthodes numériques de détection du KC, et notamment à partir des données spéculaires, d'autres classifications sont apparues. Rabinowitz et MacDonnell (Figure 1.6) ont été les premiers à caractériser ces critères.

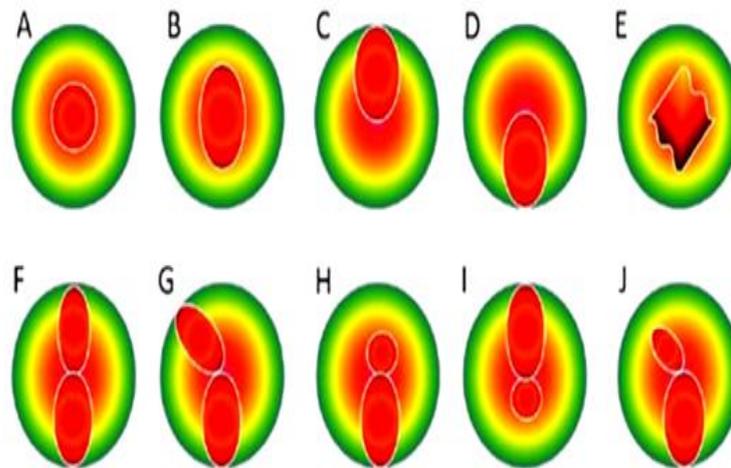


Figure I.6.Différents aspects topographiques à partir de cartes axiales en échelle absolue. D'après (Matalia and Swarup 2013)

➤ **D'autres indices vidéotopographiques (Figure I :7, I :8):**

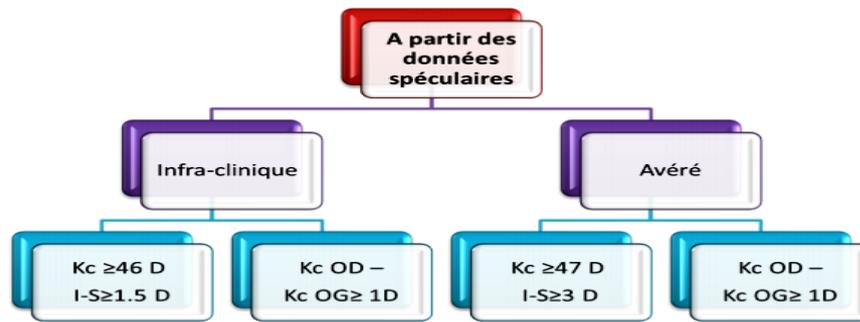


Figure I.7.Indices en topographie spéculaire permettant de distinguer les KC infracliniques des KC avérés [14].

On considère un KC avéré si : la puissance centrale de la cornée est supérieure à 47 D ; il existe une différence de plus de 1D entre l'œil droit et l'œil gauche ; des différences entre les zones supérieures et inférieures de la région paracentrale de la cornée représentent plus de 3D [14].



Figure I.8.Indices en topographie d'élévation sur la carte pachymétrique des cas suspects de KC [14].

I.7 LE DIAGNOSTIC

La détection des formes précoces de kératocône reste un défi pour les cliniciens. Outre l'examen clinique et le diagnostic du kératocône, une série de techniques d'examen a été mise en place en routine clinique pour aider au diagnostic des formes précoces de kératocône: topographie cornéenne, la pachymétrie, l'abérométrie et la lampe à fente [15].

Dans la partie qui suit, nous allons parler sur la topographie cornéenne qui fait l'objet de notre étude.

I.7.1 La topographie cornéenne

I.7.1.1 Définition

La topographie cornéenne permet de recueillir des informations relatives à la courbure ou au relief (élévation) de la cornée, grâce à la projection et l'analyse du reflet d'un motif lumineux éclairant ou balayant la cornée. Les images recueillies sont analysées de façon automatisée par un logiciel, et des cartes en couleur sont fournies au praticien pour interprétation.

I.7.1.2 Intérêt de la topographie cornéenne

La topographie de la cornée est un examen essentiel et obligatoire avant toute chirurgie réfractive. Cet examen est indispensable lors du bilan préopératoire, car il permet de vérifier l'absence d'un kératocône débutant ainsi de choisir la technique réfractive la plus appropriée pour le patient LASIK ou PKR.

Le plateau technique de la Fondation Rothschild est équipé de plusieurs topographes cornéens (Orbscan, Pentacam, OPD SCAN, iTrace, TopolyzerVario), dont les données complémentaires permettent d'établir une cartographie précise de la cornée de chaque œil [16].

- Il existe deux types d'examen topographique :

I.7.1.2.1 La topographie spéculaire

La topographie spéculaire « réflective » est fondée sur le disque de Placido. Elle permet d'obtenir une cartographie de la courbure cornéenne en fonction de la distance mesurée entre des mires circulaires concentriques projetées sur la cornée.

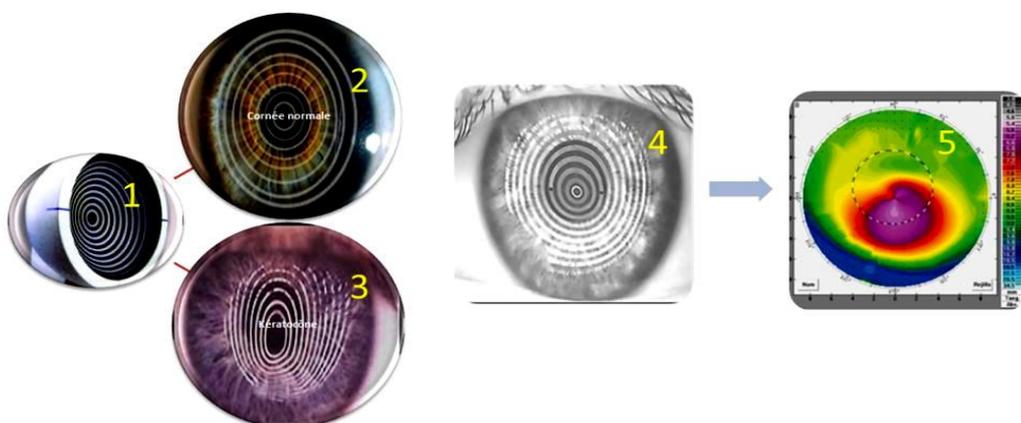


Figure I.9. Images obtenues en topographie spéculaire en utilisant le disque de Placido [14].

I.7.1.2.2 La topographie d'élevation

La topographie d'élevation mesure la forme exacte des faces antérieure et postérieure de la cornée par rapport à une sphère de référence.

L'étude de la face postérieure est importante car sa déformation, analysée par balayage d'une fente lumineuse (Orbscan) ou par imagerie Scheimpflug (Pentacam), apparaît probablement avant celle de la face antérieure.

Les informations recueillies en topographie cornéenne sont rendues sous forme de multiples cartes, il existe des cartes de courbure, de puissance, d'élevation, et même de pachymétrie.

La confrontation de cartes spéculaires et d'élevation et la recherche de différents critères de suspicion sont autant d'éléments de présomption en faveur d'un kératocône.

La surveillance topographique dans le temps sera alors primordiale pour dépister, une modification de paramètres, concomitante à l'évolution du kératocône [14].



Figure I.10.Topographe Orbscan II.

I.7.1.3 Principes de fonctionnement

Le fonctionnement des topographes cornéens dits spéculaires repose sur certains principes qui ont en commun la projection d'une image de référence sur la cornée et l'analyse de son reflet. L'analyse de la réflexion d'une mire faite de cercles concentriques sur la cornée est certainement la méthode la plus ancienne et documentée. Cette mire,

constituée d'anneaux concentriques noirs et blancs, fut inventée par l'ophtalmologiste portugais Antonio Placido en 1880. Elle est aujourd'hui située sur une coupole hémisphérique située à l'avant de l'instrument. Lors de la mesure, cette mire est éclairée et son image est projetée sur la cornée, alors que le patient en fixe un point situé au centre.

Depuis une dizaine d'années, la topographie cornéenne combine à l'analyse spéculaire une analyse en élévation, grâce au recueil d'images en coupe du mur cornéen (balayage par fentes lumineuses, ou caméra rotative Scheimpflug)

I.7.1.4 Les Cartes de topographie cornéenne

Quelles que soient les informations recueillies en topographie cornéenne, elles sont rendues sous formes de multiples cartes colorées. En général, pour les cartes de courbure, les couleurs chaudes (rouge, orange, ect.) traduisent une courbure élevée, et inversement pour les couleurs froides. Des indices numériques sont également proposés: ils varient selon les instruments (indice de régularité, valeur de l'asphéricité, etc.). Certains indices sont spécialement conçus pour dépister les formes débutantes de kératocône. [16]

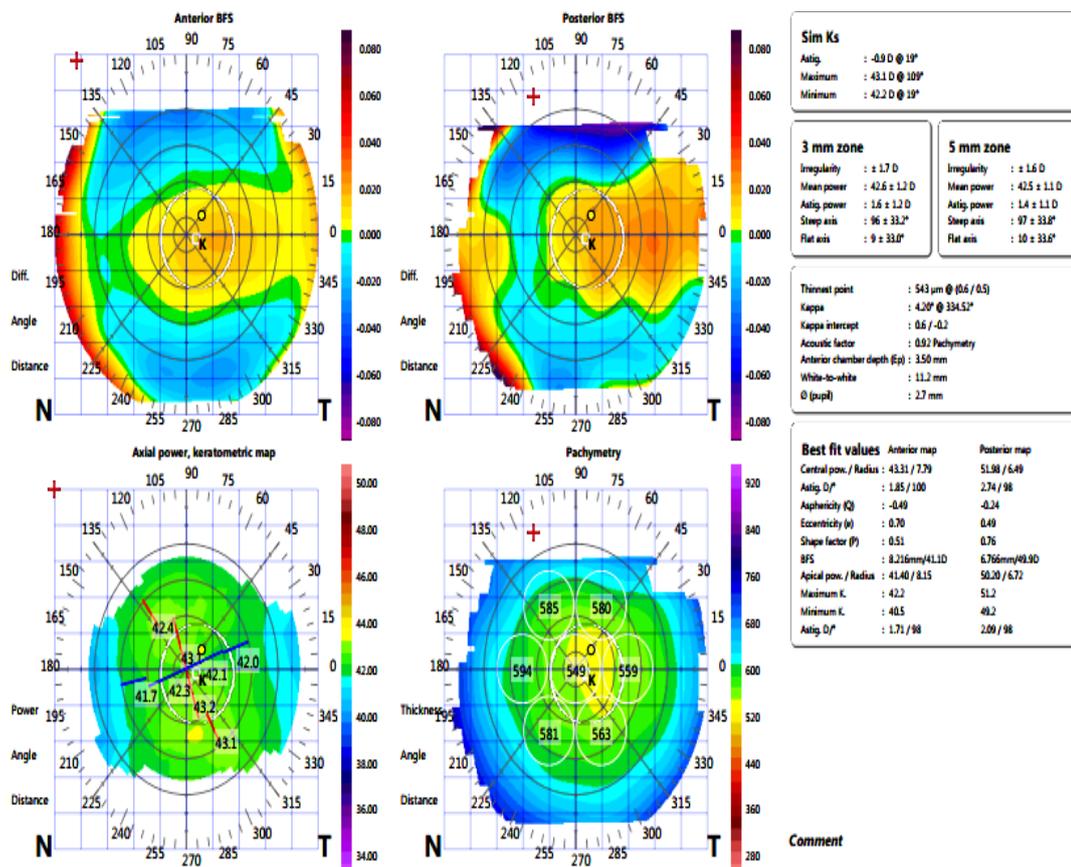


Figure I.11. Carte topographique d'un cas pathologique

I.8 TRAITEMENT DU KERATOCONE

Les objectifs de la prise en charge des patients porteurs d'un kératocône sont :

- la meilleure réhabilitation visuelle possible.
- la stabilisation de la maladie.
- éviter le stade de greffe de cornée [11].

Le kératocône peut être traité par :

- Une correction optique : lunette, lentille rigide.
- Traitement chirurgicale : Cross-linking, anneaux et la greffe de la cornée dans un stade terminal.

I.9 CONCLUSION

Dans ce chapitre, nous avons développé le concept médical du kératocône ainsi que l'anatomie pathologique de l'œil atteint de cette maladie déformante de la cornée. Les causes de la maladie et les mécanismes qui entrent en jeu dans son développement, et on a parlé de l'évolution qui n'est pas semblable pour tous les patients où elle peut rester stationnaire.

De plus nous avons défini les différents examens cornéo-topographiques dont nous avons détaillé la topographie cornéenne.

Enfin, nous avons clôturé ce chapitre avec les traitements possible pour arrêter l'évolution du kératocône ou d'améliorer les critères diagnostiques et le dépistage précoce et d'imaginer de nouveaux traitements.

CHAPITRE II Classification d'images
par CNNs

CHAPITRE II: CLASSIFICATION D'IMAGES PAR CNNS

II.1 INTRODUCTION

Le traitement d'images est un domaine important qui est utilisé dans diverses applications, telles que médicales, détection d'erreurs et d'identifications. Le traitement d'images contient différentes techniques comme l'extraction et la sélection de fonctionnalités ainsi que la classification [17].

Ces applications telles que l'identification se basent sur des algorithmes de Machine Learning (ML) et de Deep Learning (DL). En termes pratiques, l'apprentissage profond (DL) n'est qu'un sous-ensemble de l'apprentissage machine (ML). En effet, l'apprentissage profond est techniquement un apprentissage machine qui fonctionne de manière similaire (d'où l'interchangeabilité des termes), cependant ses capacités sont différentes.

Dans l'apprentissage machine même si les modèles de base s'améliorent progressivement quelles que soient leurs fonctions, ils ont encore besoin d'être guidés. Si un algorithme renvoie une prédiction inexacte, un ingénieur doit intervenir et procéder à des ajustements. Avec un modèle d'apprentissage profond, un algorithme peut déterminer seul si une prédiction est exacte ou non grâce à son propre réseau de neurones [18].

Comme le Deep Learning est une sous-catégorie du Machine Learning qui s'intéresse particulièrement à la reconnaissance des modèles et à l'apprentissage à partir des données. Le Deep Learning, spécifiquement les réseaux de neurones convolutifs (CNN) adopte une approche différente. Au lieu de définir manuellement un ensemble de règles et d'algorithmes pour extraire des fonctionnalités d'une image, ces fonctionnalités sont automatiquement apprises du processus d'apprentissage [19].

La classification automatique des images consiste à attribuer automatiquement une classe à une image à l'aide d'un système de classification. On retrouve ainsi la classification d'objets, de scènes, de textures, la reconnaissance de visages, d'empreintes digitales et de caractères. Il existe deux principaux types d'apprentissage : l'apprentissage supervisé et l'apprentissage non-supervisé.

Dans notre travail nous allons voir la classification des images avec le Deep Learning. On s'intéresse à l'approche supervisée.

II.2 MACHINE LEARNING

II.2.1 Définition

L'apprentissage automatique ou Machine Learning (ML) est une sous-section du domaine de l'intelligence artificielle ou (IA) en informatique, qui vise à apprendre aux machines à effectuer une tâche sans être explicitement programmé, et cela en utilisant un des algorithmes qu'on appellera modèles et de données [20]. L'objectif des algorithmes de Machine Learning est de minimiser ce qu'on appelle l'erreur, c'est-à-dire de se tromper le moins possible. Les méthodes d'apprentissage automatique les plus adoptées sont l'apprentissage supervisé et l'apprentissage non supervisé [21].

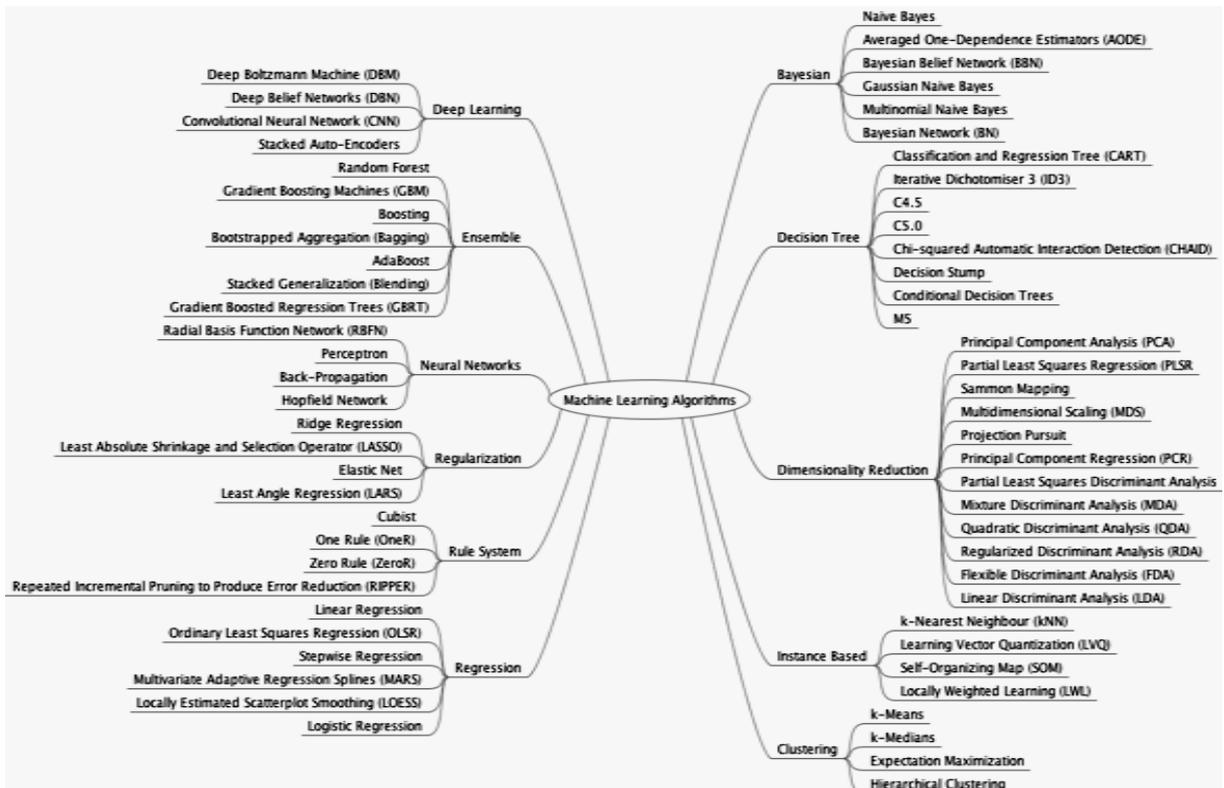


Figure II.1. Les différents algorithmes de Machine Learning [21]

II.3 DEEP LEARNING

Deep Learning ou apprentissage en profondeur (DL) est une branche du Machine Learning entièrement basée sur des réseaux de neurones artificiels.

Le concept d'apprentissage en profondeur existe depuis plusieurs années, mais il a été laissé à l'abandon faute de moyens nécessaires.

Dans le milieu des années 2000 le Machine Learning fait rage dans les compétitions de reconnaissance visuelle, en 2012 Deep Mind une startup dans le domaine de l'IA arrive dans la compétition avec un algorithme de Deep Learning qui bat largement tous les autres

compétiteurs, l'année suivante tous les compétiteurs se sont tournés vers le Deep Learning au vu des résultats obtenus.

L'avancée du DL est dû à l'augmentation en exponentiel qu'ont connu les machines en capacités de calculs, et de stockages, ainsi que la disponibilité de données de masses (big data), ses 3 ingrédients étaient nécessaires pour exploiter le potentiel du DL qui fût chose impossible dans les années 90.

Les pionniers qui ont soutenus le DL tel que Geoffrey Hinton, ou alors Yoshua Bengio qui a développé les réseaux GAN(generative adversal networks), Yann leCunqui est au cœur d'une avancée fulgurante dans le domaine de reconnaissance d'images avec les réseaux Convolutionnels CNN voir section (II.5), et son architecture LetNet. Geoffrey Hinton a prouvé que l'apprentissage profond pouvait résoudre des problèmes insolubles par d'autres approches [20].

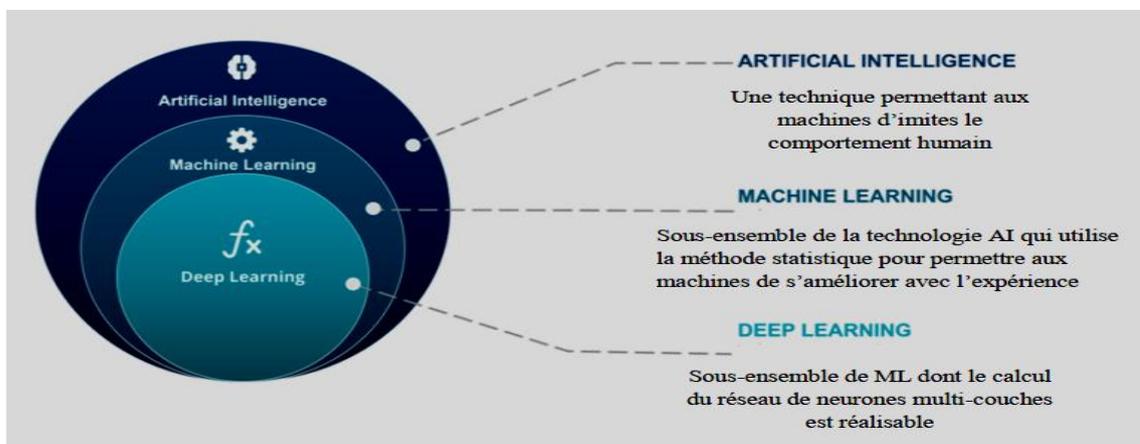


Figure II.2.La relation entre l'IA, ML et DL [26]

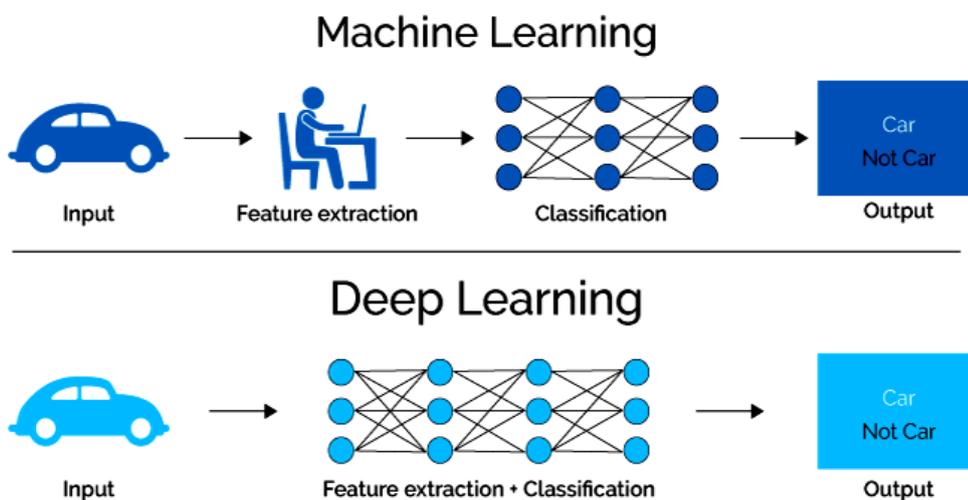


Figure II.3.ML vs DL

II.4 MACHINE LEARNING VS DEEP LEARNING

La majeure différence qu'on note entre ses 2 concepts provient de la manière dont les données sont présentées au système (modèle).

- Les algorithmes de ML nécessitent presque toujours des données structurées, alors que les réseaux d'apprentissage approfondis reposent sur des couches de réseaux de neurones artificiels (RNA).
- On voit aussi une différence au sein de l'architecture des modèles qui les composent, on note que les modèles type DL sont plus profond que les modèles type ML.
- Deep Learning n'utilise que les réseaux de neurones, alors que pour le ML les réseaux de neurones sont qu'une approche de conception des modèles parmi tant d'autres.

En considérant le fait que le DL est la prochaine étape de l'évolution du ML inculquant aux machines la manière de prendre leurs décisions de façon précise sans l'intervention de l'expert humain [20].

II.5 CRITERES DE CHOIX ENTRE LE DEEP LEARNING ET LE MACHINE LEARNING

Pour réussir une application de Deep Learning, on a besoin d'un volume de données très important (des milliers d'images) pour entraîner le modèle, en plus d'un ou de plusieurs GPU (processeur graphique) pour traiter les données rapidement.

Si aucun de ces éléments n'est disponible, il est plus judicieux d'utiliser le Machine Learning plutôt que le Deep Learning. Ce dernier est plus complexe, et nécessite un minimum de quelques milliers d'images pour obtenir des résultats fiables. L'utilisation d'un GPU haute performance, permettra une analyse plus rapide de toutes ces images par notre modèle [7].

II.6 CLASSIFICATION D'IMAGES PAR DEEP LEARNING

II.6.1 L'infographie et les images

II.6.1.1 Définition d'image

Image est une représentation planaire d'une scène ou d'un objet situé en général dans un espace tridimensionnel, elle est issue du contact des rayons lumineux provenant des objets formants la scène avec un capteur (caméra, scanner, rayons X, ...). Il ne s'agit en réalité que d'une représentation spatiale de la lumière. Est composée de points appelés Pixels.

Pixel :

Est l'unité de base permettant de mesurer la définition d'une image. Le mot pixel vient de la locution anglaise « picture element », qui signifie « élément d'image ».

II.6.1.2 Caractéristiques d'une image**II.6.1.2.1 Définition**

C'est le nombre de pixels qui composent cette image en hauteur et en largeur.

II.6.1.2.2 Résolution

C'est le nombre de pixels par unité de longueur qui est en général le pouce (1 pouce = 2,54cm).

On parle alors de pixel/pouce PPP (point par pouces) ou DPI (dots per inch) en anglais, parfois en point par cm.

Exemple : Une image de 1500 colonnes sur 1000 lignes, est d'une définition de :

$$1500 * 1000 = 1\ 500\ 000 \text{ pixels.}$$

II.6.1.2.3 Taille d'une image

La taille d'une image est le produit de sa définition par le nombre d'octets par pixel. Plus le nombre de pixels qui représente l'image est grande, plus la qualité est meilleure.

II.6.1.3 Différents types d'images**II.6.1.3.1 Image RVB**

Pour représenter la couleur d'un pixel, il faut donner trois nombres, qui correspondent au dosage de trois couleurs de base : Rouge, Vert, Bleu. On peut ainsi représenter une image couleur par trois matrices chacune correspondant à une couleur de base.

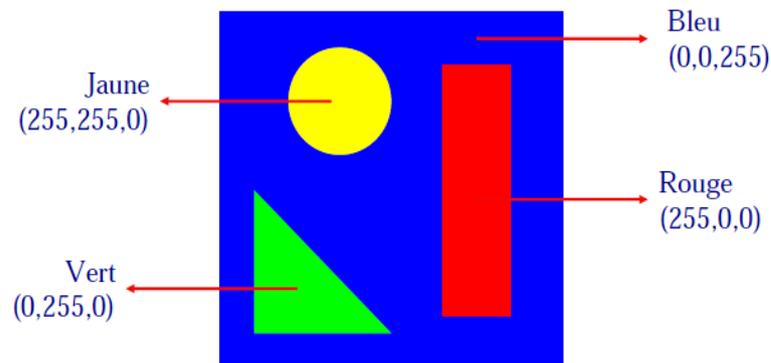


Figure II.4.Représentation d'une image RVB [22]

II.6.1.3.2 Image d'intensités

C'est une matrice dans laquelle chaque élément est un réel compris entre 0 (noir) et 1 (blanc). On parle aussi d'image en niveaux de gris, car les valeurs comprises entre 0 et 1 représentent les différents niveaux de gris.

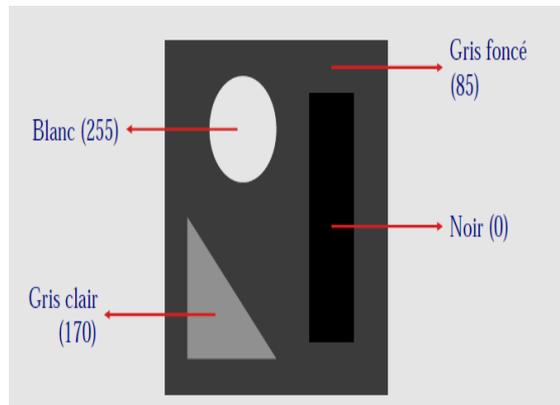


Figure II.5. Représentation d'une image ou niveaux de gris [22]

II.6.1.3.3 Image binaire

Une image binaire est une image pour laquelle chaque pixel ne peut avoir pour valeur que 0 ou 1. La manipulation de telles images regorge d'outils spécialisés ainsi que de théories mathématiques.

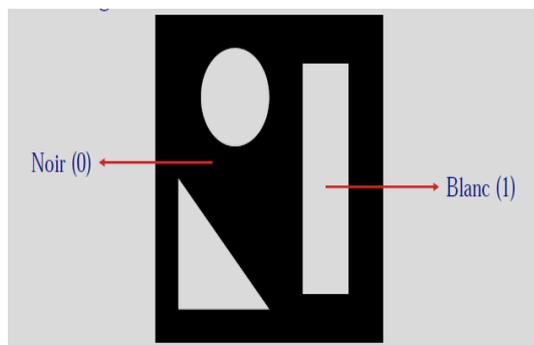


Figure II.6. Représentation d'une image binaire [22]

II.6.1.4 Codage d'images numériques

L'image numérique se représente sous la forme d'un tableau à deux dimensions contenant des valeurs entières pour les images en niveaux de gris ou des triplets de valeurs entières pour les images couleurs. La valeur stockée dans une case est codée sur un certain nombre de bits déterminant la couleur ou l'intensité du pixel, on l'appelle profondeur de codage (parfois profondeur de couleur).

Il existe plusieurs systèmes de codage, on cite par exemple :

- **RGB (RVB) :** Basé sur un mélange additif (combinaison de rayons lumineux) de trois couleurs primaires Rouge, Vert, Bleu).
- **CMYK (CMJN) :** Basé sur un mélange soustractif (combinaison de pigments colorés) de trois couleurs (Cyan, Magenta, Jaune) et du noir.
- **HLS (TLS) :** Basé sur la perception physiologique de la couleur par l'œil humain (Teinte, Luminance, Saturation).

II.6.1.5 La numérisation

La numérisation est l'étape de passage de l'état d'image physique, à la représentation de chacun de ces pixels en valeur numérique codée en binaire. Pour chaque pixel, on code en binaire chacune des 3 valeurs des composantes R, V, B de la couleur du pixel.

Le code binaire de l'image est obtenu en indiquant successivement pour chaque pixel le code binaire des 3 composantes. Si on code chaque composante sur 8 bits, chaque pixel sera donc représenté par 24 bits [23].

II.6.2 Classification des images

La classification automatique d'images est une application de la reconnaissance de forme consistant à affecter automatiquement une classe à une image à l'aide d'un système de classification, elle consiste à trouver une application de l'ensemble des objets à classer, décrit par les variables descriptives choisie dans l'ensemble des classes. La classification des images joue un rôle très important dans des applications de reconnaissance des visages, de parole et des empreintes, elle est très utilisée dans le domaine biomédical car elle aide les pathologistes à atteindre un diagnostic rapide et fiable [24].

Les méthodes de classification permettent de regrouper des objets en groupes ou classes d'objets plus homogènes. Les objets regroupés ont des caractéristiques communes, ils sont similaires mais se distinguent clairement des objets des autres classes. Les résultats des méthodes de classification sont plus ou moins différents.

La mise en œuvre d'une procédure de classification, ayant pour objectif de classer automatiquement des objets, comporte généralement deux phases fondamentales :

- **une phase d'apprentissage :** dont le but est de déterminer un espace de représentation des signaux et de rechercher les paramètres discriminants capables de caractériser chaque classe d'objets.

- **une phase de reconnaissance** : au cours de laquelle on attribue à une classe chacun des objets inconnus dans l'espace de représentation déterminé durant l'apprentissage.
- La classification peut être supervisée ou non supervisée.

II.7 LES METHODES DE CLASSIFICATION

Il existe plusieurs méthodes d'apprentissage

II.7.1 Méthodes non supervisées

Les méthodes non supervisées, elles ne nécessitent aucune base d'apprentissage et aucune tâche préalable d'étiquetage manuel. La seule intervention de l'expert se situe à la fin du processus pour identifier les classes trouvées.

II.7.2 Méthodes supervisées

Les approches supervisées nécessitent une étape d'apprentissage sur un échantillon avant de pouvoir être l'appliquer sur de nouvelles données. Les approches supervisées nécessitent généralement une interaction avec l'utilisateur pour le choix de l'échantillon d'apprentissage, source de variabilité et de non-reproductibilité des résultats [25].

Le but de ces dernier est de construire une fonction de décision à partir de données d'apprentissage projetées dans l'espace de description, la procédure qui permet de faire cette tâche est le classifieur, on a plusieurs types de classifieurs. Parmi ces classifieurs nous présentons l'algorithme des K plus proche voisins, l'algorithme "Support Vector Machine" ou "Séparateur à Vaste Marge" (SVM) et enfin l'algorithme de réseau de neurones.

II.7.3 Présentation de certaines techniques de la classification

II.7.3.1 Le classifieur K-plus proche voisin

La méthode des k-plus proche voisin est une approche basée sur l'estimation de la distance. Elle est non paramétrique et ne nécessite aucune hypothèse sur les classes. Elle consiste étant donné un point x représentant une forme à reconnaître, à déterminer la classe de chacun des k points les plus proches de x parmi l'ensemble d'apprentissage.

La décision est alors d'affecter x à la même classe que celle de son voisin le plus proche. Donc le principe général des k-plus proche voisin consiste à rechercher parmi l'ensemble d'apprentissage T , un nombre k d'individus parmi les plus proches possibles de l'individu à classer. Puis, l'individu est affecté à la classe majoritaire parmi ces k individus

trouvés. Le nombre k est fixé a priori par l'utilisateur. Une variante de la règle de la majorité consiste à prévoir un seuil s au-dessus duquel une décision de rejet est prise.

II.7.3.2 Le classifieur SVM

Le Séparateur à Vaste Marge (SVM) est un algorithme d'apprentissage défini pour la discrimination, et consiste à trouver un hyperplan qui va séparer les données et maximiser la distance entre ces 2 classes.

Le principe du SVM est de chercher parmi les hyperplans valides, l'hyperplan dont la distance minimale aux exemples d'apprentissage est maximale. Cette distance est appelée distance marge entre l'hyperplan et les exemples.

SVM peut fonctionner avec une séparation non linéairement des classes (s'il n'y a pas de séparation linéaire entre les données). Dans ce cas, l'espace des données sera transformé en un autre espace qui est appelé espace de représentation. La transformation non-linéaire des données peut permettre une séparation linéaire des exemples dans cet espace, cette transformation est effectuée via une fonction noyau (noyau polynômial, gaussien, sigmoïde ou Laplacien) [24].

II.7.3.3 Les réseaux de neurones artificiels (RNA)

Dans ce titre, nous parlons sur les réseaux de neurones en montrant leurs principes et typologies. Dans le prochain titre, nous détaillons les réseaux neurones convolutionnels et la raison qui nous a poussé à choisir cette typologie.

II.7.3.3.1 Modélisation d'un neurone : une inspiration biologique

Dans les réseaux de neurones, l'élément de base est un neurone artificiel qui correspond à un modèle issu des observations faites sur les neurones biologiques.

Le neurone biologique est une cellule excitable, Il reçoit et traite en permanence des informations en provenance des dendrites, des stimuli qui vont agir sur la répartition des ions de part et d'autre de sa membrane. Lorsque la somme de ces courants électriques atteint un certain seuil, l'équilibre électrochimique est modifié localement et un influx nerveux (un courant électrique) est déclenché, se propage le long de l'axone puis atteint les neurones voisins reliés par les synapses. On parle de potentiel d'activation [26].

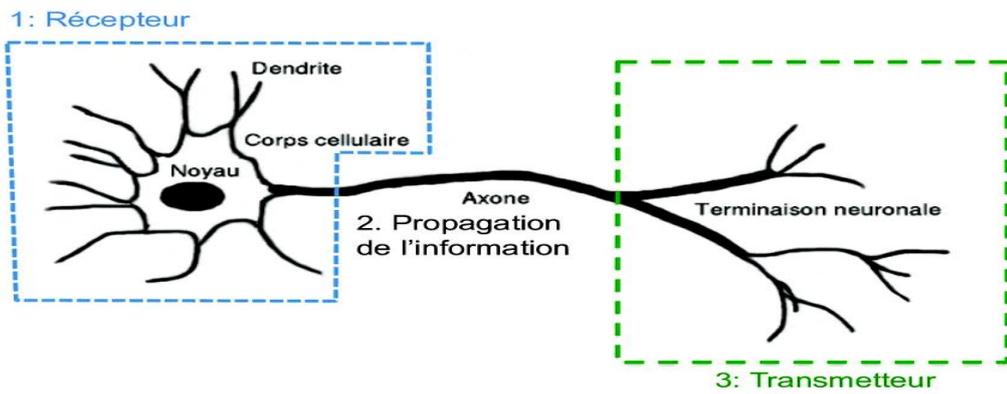


Figure II.7. Schémas d'un neurone biologique.

II.7.3.3.2 Quelle est le lien entre les neurones biologiques et neurones artificiels?

Procédons à une comparaison simple des étapes principales de l'algorithme du perceptron avec les éléments constitutifs des neurones biologiques. Ce choix d'algorithme se justifie car il se rapproche au mieux du fonctionnement des neurones biologiques :

- Les synapses/dendrites : pondération de chaque élément en entrée w_{ix}
- Corps cellulaires : application d'une fonction d'activation f à la somme des entrées pondérées
- Axone : sortie de notre modèle [27].

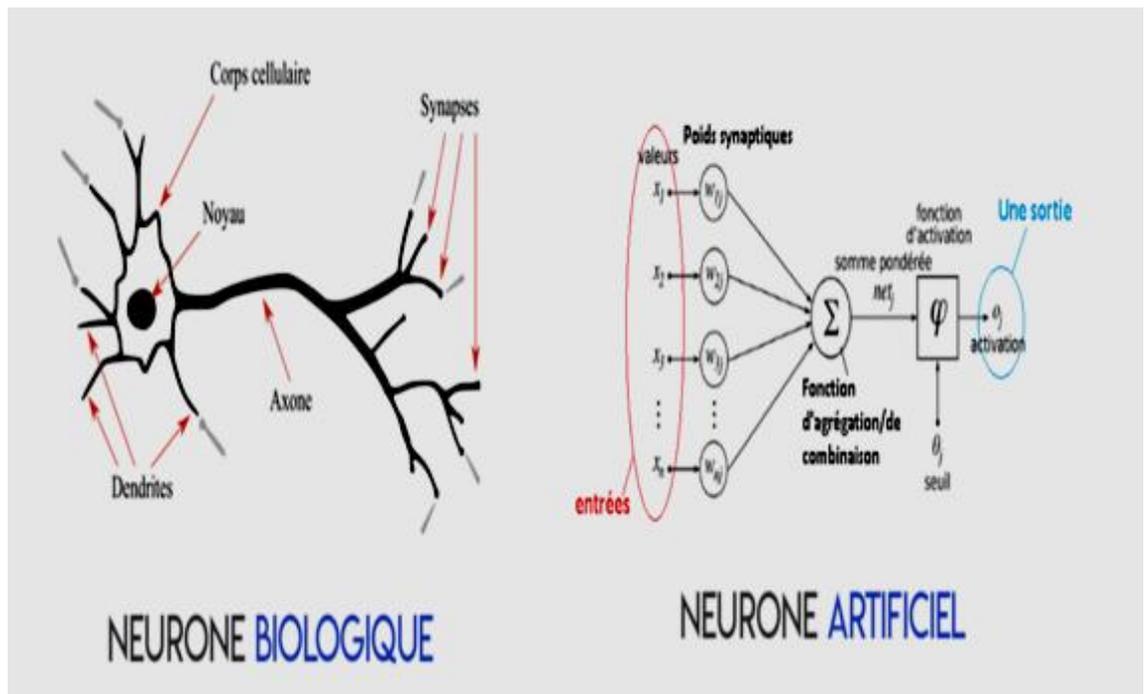


Figure II.8. Le neurone biologique et le neurone artificiel.

II.7.3.3 Principe des réseaux de neurones

Les réseaux de neurones proposent une simulation du fonctionnement de la cellule nerveuse à l'aide d'un automate : le neurone formel.

Les réseaux neuronaux sont constitués d'un ensemble de neurones (nœuds) connectés entre eux par des liens qui permettent de propager les signaux de neurone à neurone. Grâce à leur capacité d'apprentissage, les réseaux neuronaux permettent de découvrir des relations complexes non-linéaires entre un grand nombre de variables, sans intervention externe. De ce fait, ils sont largement utilisés dans de nombreux problèmes de classification (ciblage marketing, reconnaissance de formes, traitement de signal, ...) d'estimation (modélisation de phénomènes complexes, ...) et prévision (bourse, ventes, ...). Il existe un compromis entre clarté du modèle et pouvoir prédictif. Plus un modèle est simple, plus il sera facile à comprendre, mais moins il sera capable de prendre en compte des dépendances trop variées [27].

II.7.3.4 Typologie des réseaux neuronaux

Il existe beaucoup de types de réseaux neurones, chaque type étant développé pour un objectif particulier.

a) Neurone Formel

Un neurone artificiel ou formel est une fonction mathématique non linéaire. Son fonctionnement s'inspire directement du mécanisme du neurone biologique, en cherchant à imiter son processus d'apprentissage. Il est généralement constitué de plusieurs entrées et d'une seule sortie. Chacune de ces entrées « $x_1; \dots; x_n$ », est associée à un poids appelé poids synaptique ou coefficients numérique « $W_1; \dots; W_n$ ». Ces derniers sont ajustés lors de la phase d'apprentissage.

Le neurone formel calcule la somme pondérée des entrées qu'il perçoit auquel se rajoute un seuil qui est fixé au début par l'utilisateur. Ensuite, il applique à la valeur obtenue une fonction non linéaire qu'on appelle fonction d'activation. Enfin, la valeur finale est affectée en sortie du neurone. Le choix de la fonction d'activation dépend de l'utilisateur ainsi que du problème étudié. Ce choix est très important car il influence les propriétés du neurone formel. Les fonctions d'activation les plus utilisées sont les fonctions sigmoïdes.

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

Il existe cependant d'autres fonctions : le pas unitaire, la fonction linéaire souillée, la gaussienne ou encore l'identité [28].

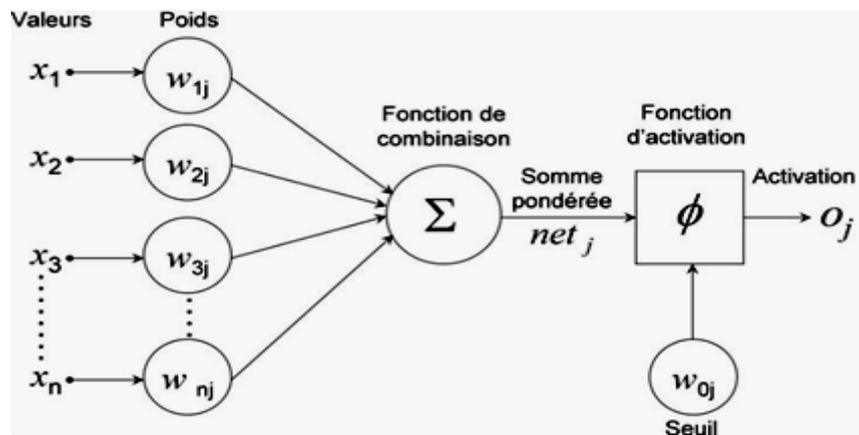


Figure II.9.Présentation d'un neurone formel

b) Neurones multicouches (Multi Layer Perceptron)

Le perceptron multicouche ce modèle est une extension du perceptron monocouche, avec une ou plusieurs couches cachées (multi layer perceptron MLP) entre l'entrée et la sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (sauf pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les cellules d'une même couche. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes.

Il peut résoudre des problèmes non-linéairement séparables et des problèmes logiques plus compliqués, et notamment le fameux problème du XOR. Il suit aussi un apprentissage supervisé [27].

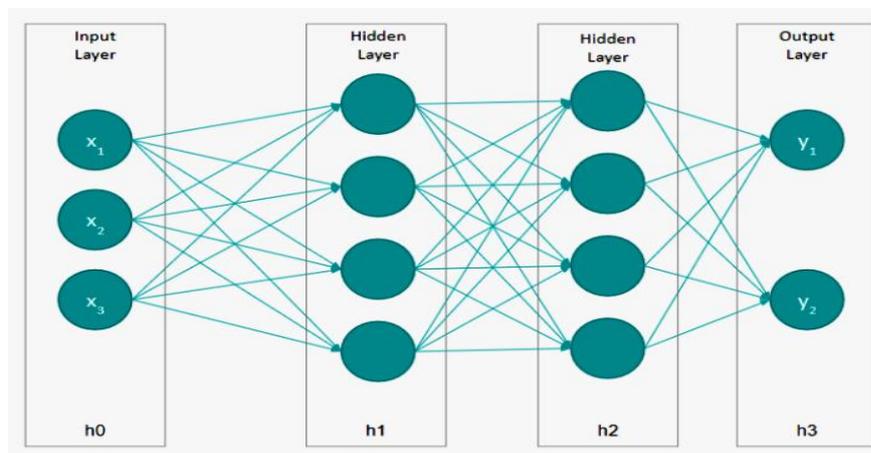


Figure II.10.Architecture d'un perceptron multicouche

II.7.3.4 Réseaux Neurones Convolutionnels (CNN)

En apprentissage automatique, un réseau de neurone convolutifs (ou réseau de neurones à convolution, ou CNN ou ConvNet) est un type de réseau de neurones artificiels acycliques (Feed-forward) dans lequel le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux. Les neurones de cette région du cerveau sont arrangés de sorte à ce qu'ils correspondent à des régions qui se chevauchent lors du pavage du champ visuel. Leur fonctionnement est inspiré par les processus biologiques, ils consistent en un empilage multicouche de perceptrons, dont le but est de prétraiter de petites quantités d'informations. Les réseaux neuronaux convolutifs ont de larges applications dans la reconnaissance d'image et vidéo, les systèmes de recommandation et le traitement du langage naturel [26].

II.7.3.5 Avantages du CNN par rapport au MLP

Supposons que nous disposions d'un ensemble de données d'image de 28 x 28 pixels. Perceptron multicouche aura besoin de 784 poids d'entrée plus un biais. En aplatissant une image comme le ferait un MLP, nous perdons la relation spatiale des pixels de l'image.

Le CNN, en revanche, peut apprendre des caractéristiques d'image complexes en préservant la relation spatiale entre les pixels de l'image. Pour ce faire, il empile des couches convolutives. Les neurones des couches supérieures ayant un champ réceptif plus large reçoivent des informations. Des neurones des couches inférieures ayant un champ réceptif plus petit. Le CNN apprend une hiérarchie de caractéristiques de plus en plus complexes à partir des données d'entrée à mesure qu'elles traversent le réseau.

Dans le CNN, les neurones (ou filtres) de la couche convolutive ne sont pas tous connectés aux pixels de l'image d'entrée, comme c'est le cas dans le réseau multicouche dense. Par conséquent, un CNN est également appelé un réseau neuronal clairsemé.

Un avantage distinct du CNN par rapport au MLP est le nombre réduit de poids nécessaires à la formation du réseau.

II.8 RESEAUX DE NEURONES CONVOLUTIFS (CNNS)

II.8.1 Principe d'architecture d'un CNN

Les réseaux de neurones convolutifs sont à ce jour les modèles les plus performants pour classer des images. Ils comportent deux parties bien distinctes une première partie que l'on appelle la partie convolutive du modèle et la seconde partie, que l'on va appeler la partie classification du modèle qui correspond à un modèle MLP (Multi Layers Perceptron).

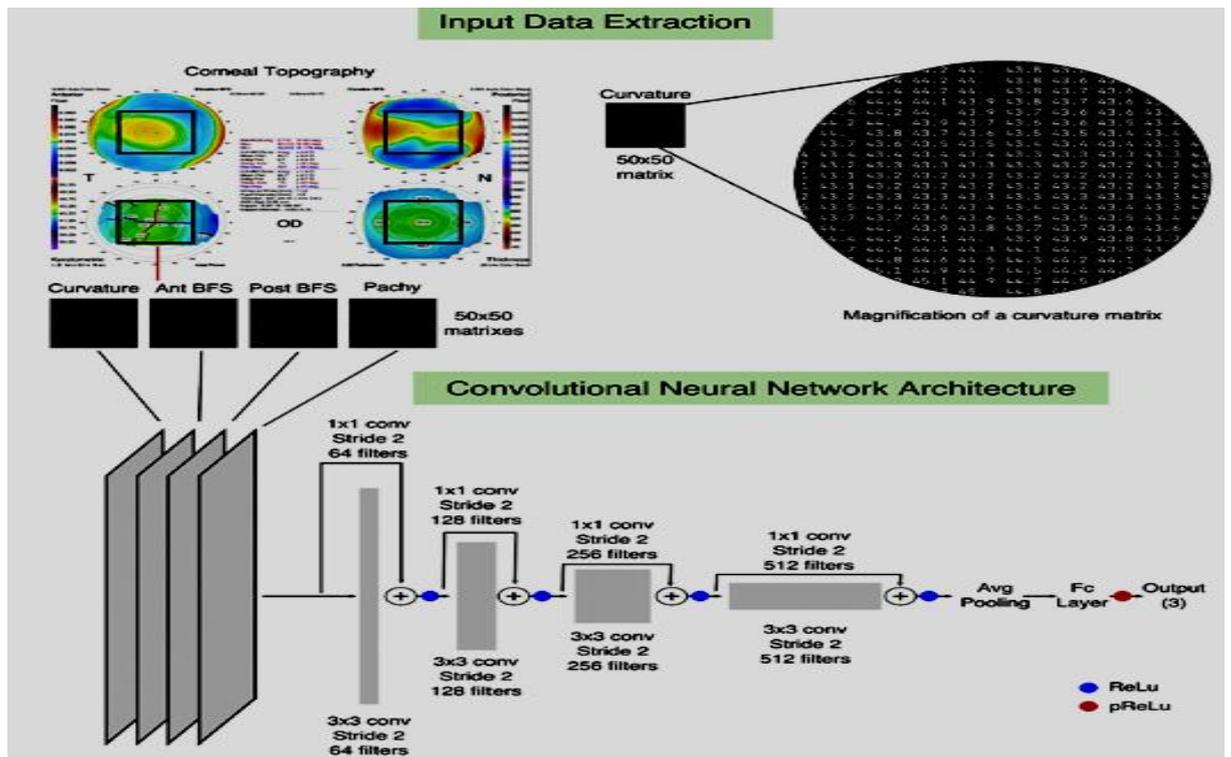


Figure II.11. Architecture d'un réseau de neurones convolutifs

II.8.2 La convolution

Est le processus par lequel une fonction est appliquée à une matrice pour en extraire des informations spécifiques de la matrice. La fonction est implémentée sous la forme d'une fenêtre coulissante à travers la matrice, et elle est plus communément appelée filtre convolutif ou noyau [29].

La convolution est un outil mathématique simple qui est très largement utilisé pour le traitement d'image, ce qui explique que les réseaux de neurones à convolution soient particulièrement bien adaptés à la reconnaissance d'image.

La convolution agit comme un filtrage. On définit une taille de fenêtre qui va se balader à travers toute l'image (rappelez-vous qu'une image peut être vue comme étant un tableau). Au tout début de la convolution, la fenêtre sera positionnée tout en haut à gauche de l'image puis elle va se décaler d'un certain nombre de cases (c'est ce que l'on appelle le pas) vers la droite et lorsqu'elle arrivera au bout de l'image, elle se décalera d'un pas vers le bas ainsi de suite jusqu'à ce que le filtre ait parcouru la totalité de l'image [26].

II.8.3 Architecture de réseaux de neurones convolutionnels

Les réseaux neuronaux convolutifs sont composés de trois types fondamentaux de couches :

II.8.3.1 Couches convolutionnelles

Reconnaître des objets dans des images revient à comparer l'image pixel par pixel, pour trouver des caractéristiques. Bien qu'efficaces pour le traitement d'images, les réseaux de neurones multicouches, ont beaucoup de mal à gérer des images de grande taille, ce qui est dû à la croissance exponentielle du nombre de connexions avec la taille de l'image.

Par exemple une image de taille 200 x 200 x 3 (200 de large, 200 de haut, 3 canaux de couleur), conduirait ainsi à traiter 120 000 entrées par neurone ce qui, multiplié par le nombre de neurones, devient énorme. Une couche de convolution permet de reconnaître des formes sur une image, généralement avec des filtres de taille 2 x 2 ou 3 x 3 pixels, ce que limite le nombre d'entrées.

Pour chaque filtre, et pour tout carré de la taille du filtre sur la matrice d'entrée, les cases correspondantes de la matrice de sorties sont égales à la somme de toutes les valeurs du filtre, multipliées respectivement par ceux des carrés d'entrée. Ainsi la taille de la matrice de sortie est égale à celle de l'entrée moins deux lignes et deux colonnes.

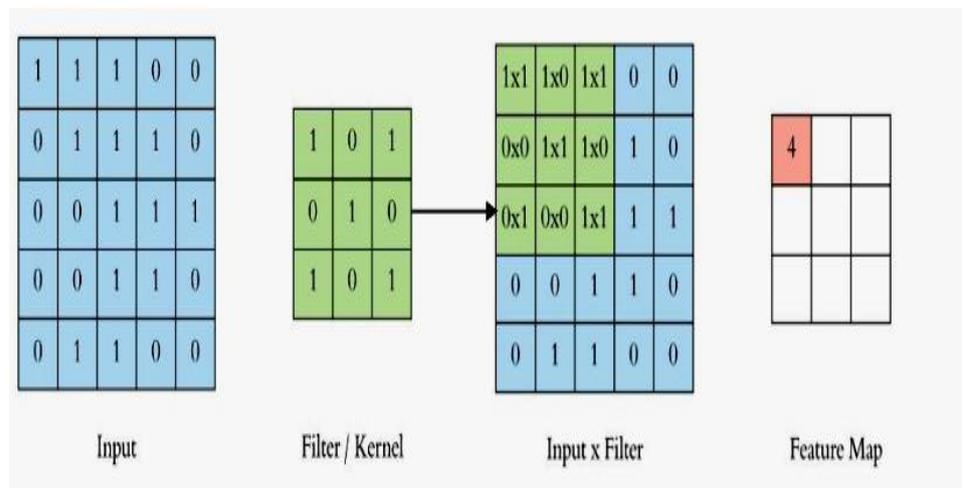


Figure II.12.Opération d'une convolution sur image de 5*5pixel

II.8.3.2 Couches de pooling

Sont placées entre deux couches de convolution, ces couches abaissent les données de l'image extraites par les couches convolutionnelles pour réduire la dimension de la carte des caractéristiques afin de diminuer le temps de traitement.

Une couche de pooling permet de réduire la taille de la matrice d'entrée, d'augmenter la vitesse tout en gardant les informations les plus importantes.

Il existe deux types de pooling :

•Le Maximum Pooling

Divise la taille de l'entrée par 2 en prenant le maximum des carrés de taille 2 x 2 pixels.

•L'Average Pooling

Divise la taille de l'entrée par 2 en calculant la moyenne des carrés de taille 2 x 2 pixels.

Le maximum pooling est le plus utilisé surtout pour la reconnaissance des objets de grandes tailles et complexes.

II.8.3.3 Couches entièrement connectées

La couche entièrement connectée est un perceptron multicouche qui utilise une fonction d'activation softmax dans la couche de sortie. Le terme «entièrement connecté» implique que chaque neurone de la couche précédente est connecté à chaque neurone de la couche suivante. La sortie des couches convolutionnelles et de regroupement représente les fonctionnalités de haut niveau de l'image d'entrée.

La couche entièrement connectée a pour le but d'utiliser ces fonctionnalités pour classer l'image d'entrée dans différentes classes en fonction du jeu de données d'apprentissage.

II.8.4 Fonctionnement d'un réseau de neurones convolutifs

II.8.4.1 Couche de convolution

La tâche de la couche de convolution est de chercher les caractéristiques présentes dans l'image, pour réaliser cette tâche on applique des filtres à l'image.

Un filtre est une matrice souvent carré (2 x 2 ou 3 x 3) qu'on va balayer sur l'ensemble d'image, en sortie on obtient une image de taille réduite qu'on appelle « cartes de convolution ». Dans la couche de convolution on applique un ensemble K de filtres, on obtient alors une pile de K activations maps (cartes de convolution).

- Chaque filtre détecte une caractéristique particulière à chaque emplacement de l'entrée, la sortie Y_j^i ($j \in \{1..K\}$) de la couche C se compose de K caractéristiques.
- Chaque carte de convolution M_j^i est le résultat d'une somme de convolution des cartes de la couche précédente M_j^{i-1} par son noyau de convolution respectif.

- Un biais b_j^i est ensuite ajouté et le résultat est passé à une fonction de transfert non-linéaire, alors Y_j^i est calculé [12]:

$$Y_j^i = b_j^i + \sum_{n=1}^N Y_n^{i-1} * k_n^i$$

II.8.4.2 Unités linéaires rectifiées (ReLU)

Il est possible d'améliorer l'efficacité du traitement en intercalant entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie.

La fonction ReLU (abréviation de : Unités Rectifié linéaires) :

$$Y(x) = \max(0, x)$$

Cette fonction force les neurones à retourner des valeurs positives.

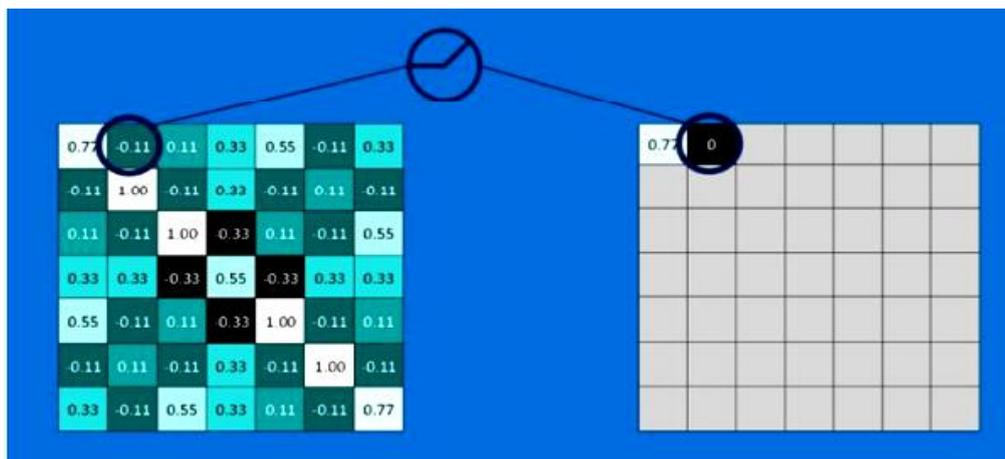


Figure II.13.Fonction Relu

II.8.4.3 La couche de pooling

La couche de pooling (également appelée sous-échantillonnage) réduit la dimensionnalité de chaque carte d'entités mais conserve les informations les plus importantes. La mise en commun spatiale peut être de différents types : Max, Moyenne, Somme etc.

Dans le cas d'un pool maximum, nous définissons un voisinage spatial (par exemple, une fenêtre 2×2) et prenons l'élément le plus grand de la carte d'entités rectifiées dans cette fenêtre. Au lieu de prendre l'élément le plus grand, nous pourrions également prendre la moyenne (moyenne Pooling) ou la somme de tous les éléments dans cette fenêtre. La figure montre un exemple d'opération de regroupement maximal sur une carte d'entité rectifiée (obtenue après convolution + operation ReLU).

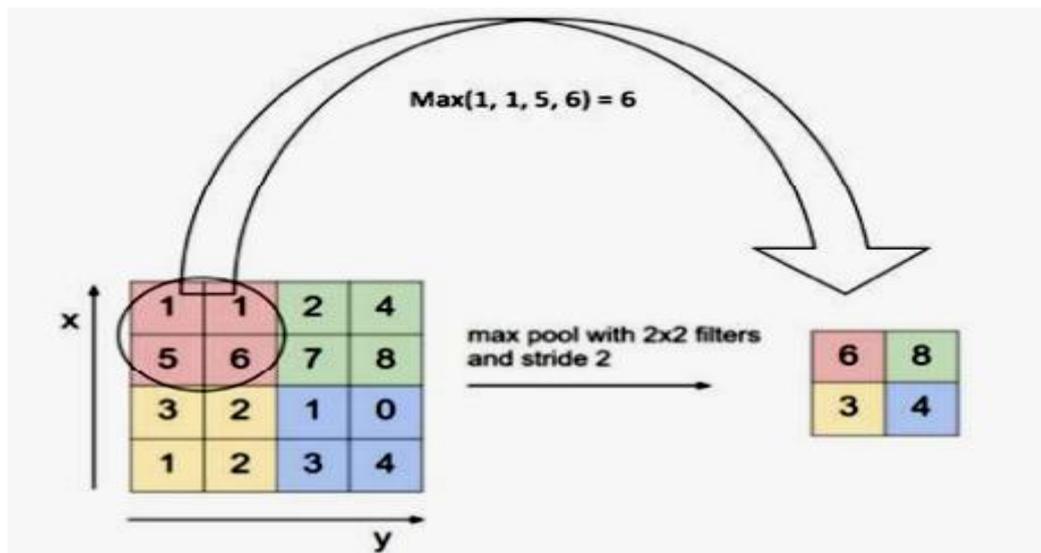


Figure II.14.Max-Pooling avec un filtre 2x2 et un pas de 2

Nous faisons glisser notre fenêtre de 2 x 2 par 2 cellules et prenons la valeur maximale dans chaque région. Comme le montre la figure 14, cela réduit la dimensionnalité de notre carte de caractéristiques. Dans le réseau représenté sur la Figure 15, l'opération de regroupement est appliquée séparément à chaque carte de caractéristique (notez que, grâce à cela, nous obtenons trois cartes de sortie à partir de trois cartes d'entrée)

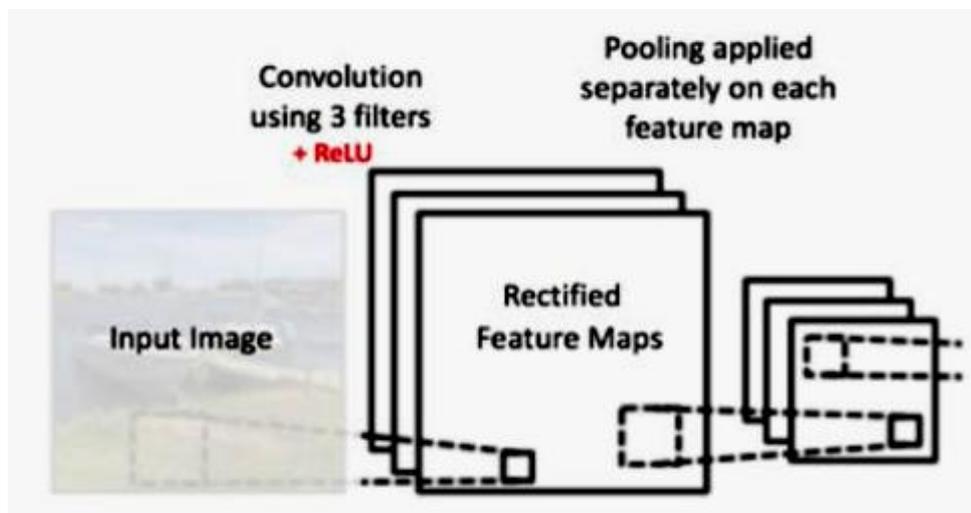


Figure II.15.Mise en commun appliquée aux cartes de fonctions rectifiées [30].

La fonction de Pooling consiste à réduire progressivement la taille spatiale de la représentation d'entrée. En particulier, la mise en commun

- Rend les représentations d'entrée (dimension caractéristique) plus petites et plus faciles à gérer.
- Réduit le nombre de paramètres et de calculs dans le réseau.

- Rend le réseau invariant aux petites transformations, distorsions et translations dans l'image d'entrée (une petite distorsion en entrée ne changera pas la sortie de Pooling - puisque nous prenons la valeur maximum / moyenne dans un voisinage local).
- Nous aide à arriver à une représentation invariable presque à l'échelle de notre image (le terme exact est "équivalent"). Ceci est très puissant car nous pouvons détecter des objets dans une image, peu importe où ils se trouvent.

II.8.4.4 Couche entièrement connectée

Les couches totalement connectées dans un réseau convolutif sont pratiquement un perceptron multicouche (généralement deux à trois couches), qui vise à cartographier le volume d'activation de la combinaison des différentes couches précédentes en une distribution de probabilité de classe.

La couche de sortie du perceptron multicouche aura M_1^{l-1} sorties, c'est-à-dire des neurones de sortie ou i indique le nombre de couches dans le perceptron multicouche. La principale différence par rapport à un perceptron multicouche standard est la couche d'entrée où, au lieu d'un vecteur, on prend un volume d'activation en entrée. La couche entièrement connectée est définie comme :

$$Y_i^l = f(Z_i^l) \quad \text{avec} \quad Z_i^l = \sum_{j=i}^{m^{l-1}} W_{i,j}^l y_j^{l-1}$$

Le but de la structure complète entièrement connectée est de régler les paramètres de poids $W_{i,j}^l$.

II.8.4.5 L'entraînement d'un réseau de neurone convolutionnelle

L'entraînement d'un CNN consiste à déterminer et à calculer empiriquement la valeur de chacun de ses poids.

Le principe est le suivant : le CNN traite une image (de la base de données d'entraînement) et en sortie il fait une prédiction, c'est-à-dire qu'il dit à quelle classe il pense que cette image appartient. Sachant qu'on connaît préalablement la classe de chacune des images d'entraînement, on peut vérifier si ce résultat est correct. En fonction de la véracité de ce résultat, on met à jour tous les poids du CNN selon un algorithme qui s'appelle la rétropropagation du gradient de l'erreur.

Lors de la phase d'entraînement du modèle, le processus expliqué ci-dessus est répété plusieurs fois et avec la totalité des images de la base de données d'entraînement. Le but étant

que le modèle classifie au mieux ces données. Lorsque le modèle a fini de mettre à jour ses poids, on évalue le modèle en lui présentant la base de données de validation. Il classe toutes ces images (qui sont des images que le modèle n'a jamais vues) et on calcule son taux de bonne classification, c'est ce qu'on appelle la précision du modèle [30].

II.8.5 Exemples d'architectures

II.8.5.1 Alexnet

AlexNet est un réseau de neurones de convolution pré-entraîné formé sur plus d'un million d'images de la base de données ImageNet. Le réseau a une profondeur de 8 couches et permet de classer les images en 1 000 différentes catégories d'objets. En conséquence, le réseau a appris des représentations de fonctions riches pour une large gamme d'images. Le réseau a une taille d'entrée d'image de 227 sur 227.

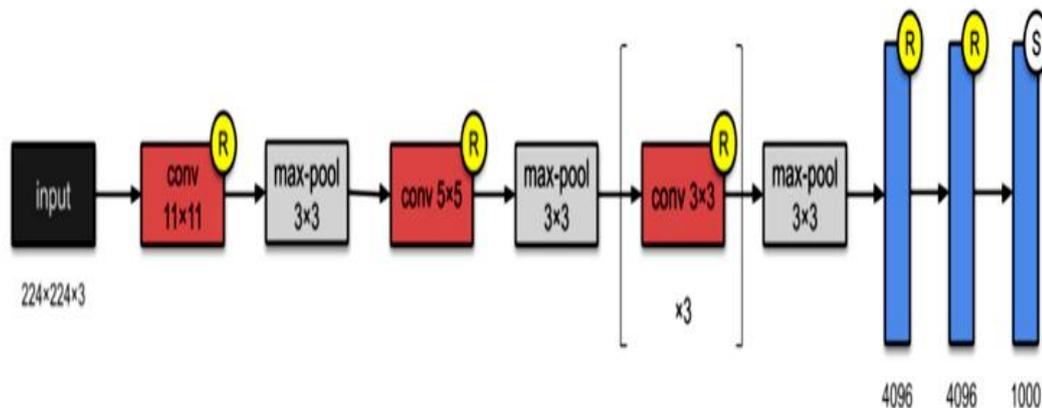


Figure II.16. Architecture d'AlexNet[19].

II.8.5.1.1 Architecture du modèle 01 (AlexNet)

AlexNet comprend 5 couches convolutives et 3 couches entièrement connectées (FC). Les noyaux de convolution multiples (filtres) extraient des caractéristiques intéressantes dans une image.

Dans une seule couche de convolution, il y a généralement plusieurs noyaux de la même taille. Par exemple, la première couche de convergence d'AlexNet contient 96 noyaux de taille 11x11x3. Notez que la largeur et la hauteur du noyau sont généralement les mêmes et que la profondeur correspond au nombre de canaux.

Les deux premières couches convolutives sont suivies des couches superposées de regroupement maximal. Les troisième, quatrième et cinquième couches convolutives sont connectées directement. La cinquième couche de convolution est suivie par une couche de regroupement maximum se chevauchant, dont la sortie se trouve dans une série de deux couches entièrement connectées. La deuxième couche entièrement connectée alimente un classifieur softmax avec 1000 étiquettes de classe. La non-linéarité ReLU est appliquée après toutes les couches de convolution et entièrement connectées.

La non-linéarité ReLU des premières et secondes couches de convolution est suivie d'une étape de normalisation locale avant la mise en pool [31].

II.8.5.2 ResNet

ResNet (Un réseau neuronal résiduel) a une idée simple : alimenter la sortie de deux couches convolutionnelles successives et contourner l'entrée aux couches suivantes. L'idée se base sur la connexion de raccourci d'identité, "identity shortcut connection" qui saute un ou deux couches [32].

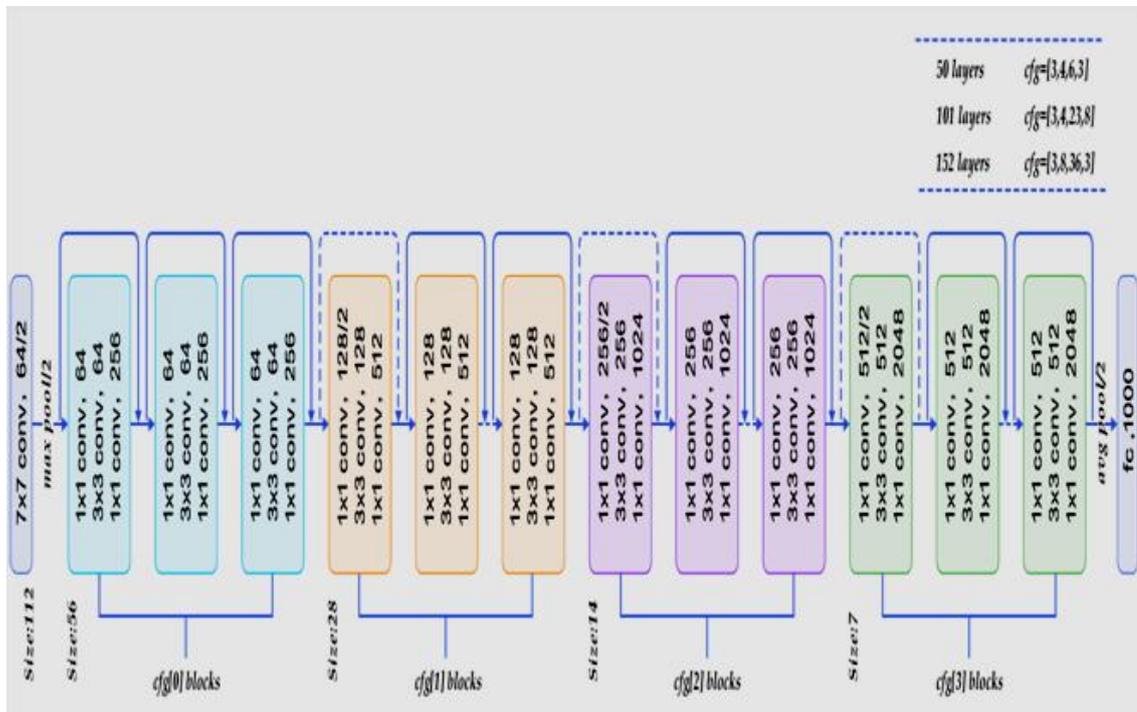


Figure II.17. Architecture de ResNet [31]

II.8.5.3 LeNet-5

LeNet-5, un réseau convolutif pionnier à 7 niveaux par LeCun et al en 1998, qui classifie les chiffres, a été appliqué par plusieurs banques pour reconnaître les nombres écrits à la main sur les chèques (chèques) numérisés en images d'entrée 32x32 pixels en niveaux de gris. La capacité de traiter des images à plus haute résolution nécessite des couches plus grandes et plus convolutives, cette technique est donc limitée par la disponibilité des ressources informatiques.

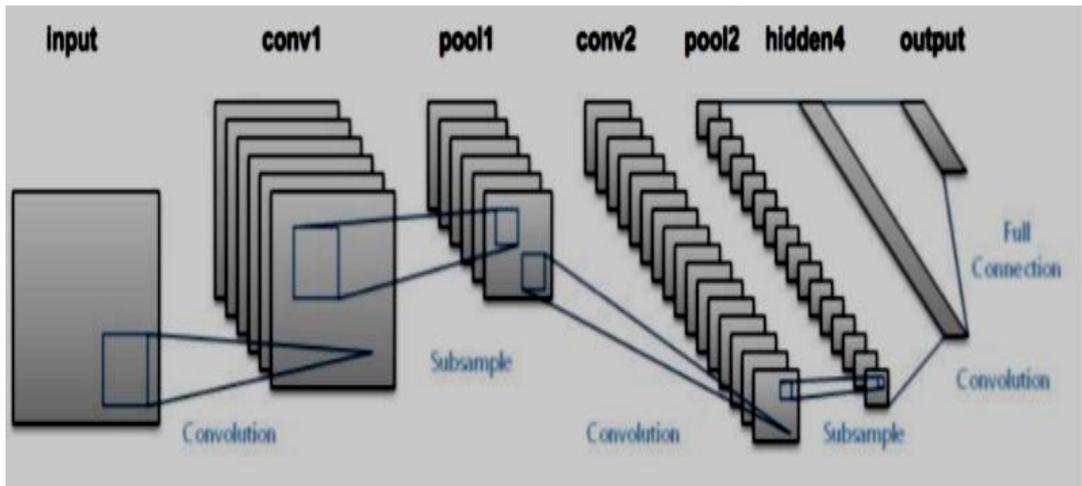


Figure II.18. Architecture LeNet-5 [31]

II.8.5.4 ZFNet

Il a atteint un taux d'erreur parmi les 5 premiers de 14,8%, soit déjà la moitié du taux d'erreur non neuronal. Il s'agissait principalement d'une réalisation en modifiant les hyperparamètres d'AlexNet tout en conservant la même structure avec des éléments d'apprentissage profond supplémentaires.

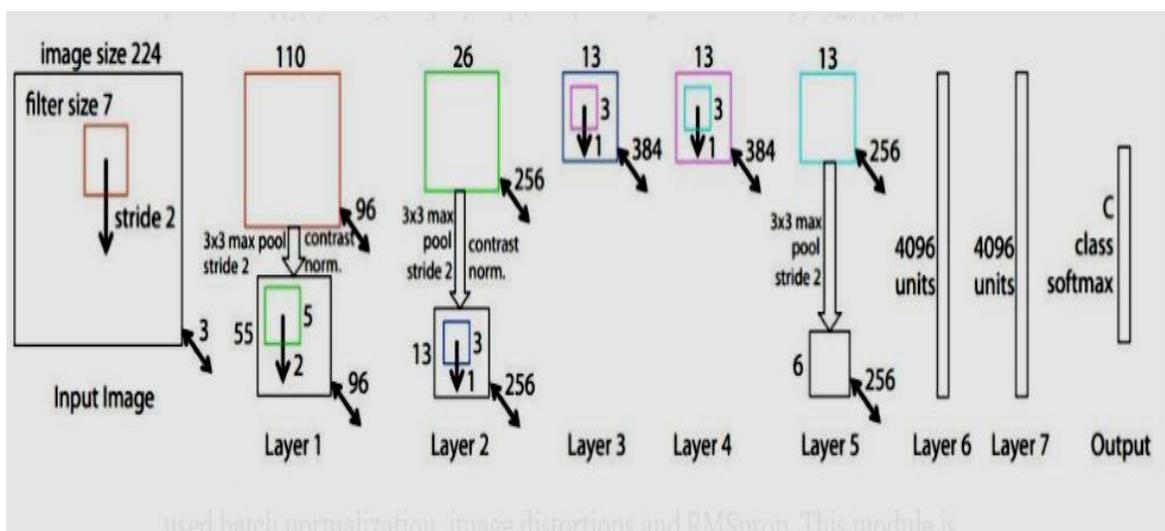


Figure II.19. Architecture ZFNet [31].

II.8.5.5 VGGNet

VGGNet se compose de 16 couches convolutives et est très attrayant en raison de son architecture très uniforme. Similaire à AlexNet, seulement 3x3 convolutions, mais beaucoup de filtres. La configuration du poids du VGGNet est accessible au public et a été utilisée dans de nombreuses autres applications et défis comme extracteur de fonctionnalités de base. Cependant, VGGNet se compose de 138 millions de paramètres, ce qui peut être un peu difficile à gérer.

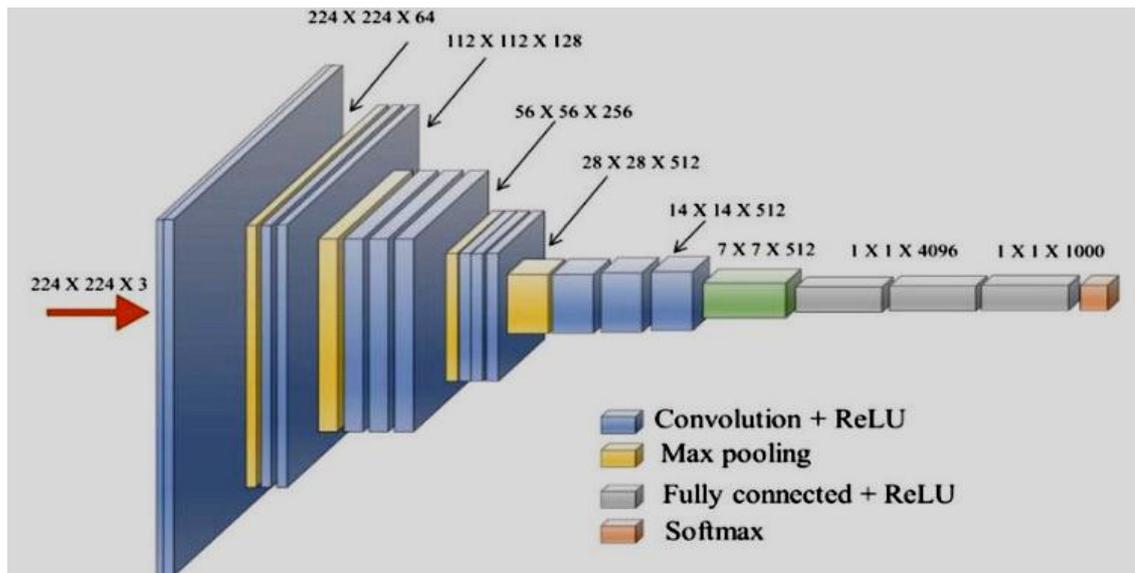


Figure II.20. Architecture VGGNet

II.8.5.6 GoogLeNet

Le gagnant de l'ILSVRC 2014 et de l'architecture GoogLeNet est également connu sous le nom de module de lancement. Il va plus loin dans les chemins parallèles avec différentes tailles de champ réceptif et il a atteint un taux d'erreur parmi les 5 premiers avec 6,67%.

Cette architecture se compose de 22 couches en profondeur. Il réduit le nombre de paramètres de 60 millions (AlexNet) à 4 millions [33]

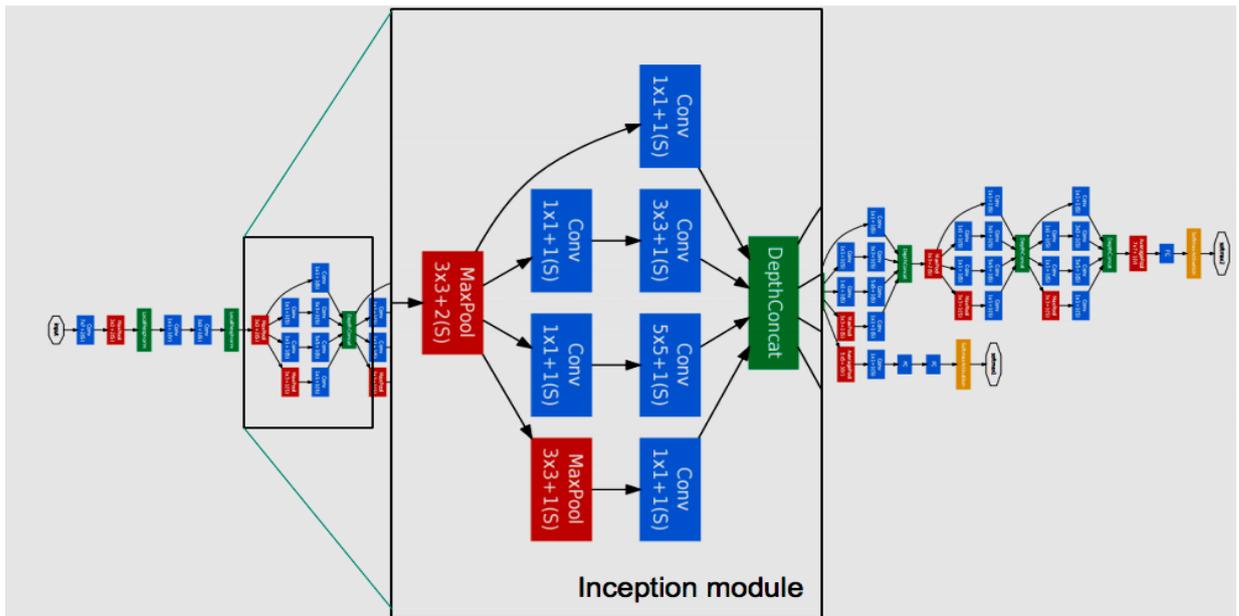


Figure II.21. Architecture GoogLeNet [33]

II.9 INDICATEURS DE PERFORMANCE EN CLASSIFICATION

II.9.1.1 Perte logarithmique

La Perte logarithmique ou Log Loss, fonctionne en pénalisant les fausses classifications. Cela fonctionne bien pour la classification multi-classes. Lorsqu'on travaille avec Log Loss, le classificateur doit attribuer une probabilité à chaque classe pour tous les échantillons. Supposons qu'il existe N échantillons appartenant à M classes, alors la perte logarithmique est calculée comme suit :

$$LogLoss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} * \log(p_{ij})$$

- y_{ij} indique si l'instance i appartient à la classe j ou pas.
- p_{ij} indique la probabilité que l'instance i appartienne à la classe j .
- Une valeur proche de 0 indique une bonne performance [7].

II.10 CONCLUSION

Ce chapitre a été consacré à la présentation des approches de la classification ainsi que leurs intérêts dans le domaine d'imagerie. Dans le but d'introduire les réseaux de neurones convolutionnels, une explication de concepts plus généraux sur le Machine Learning a été présentée. Enfin, nous avons présenté les architectures les plus courantes des CNNs et quelques métriques de leur évaluation.

CHAPITRE III

Implémentation, résultats et discussion

CHAPITRE III: IMPLEMENTATION, RESULTATS ET DISCUSSIONS

III.1 INTRODUCTION

Dans ce chapitre, nous allons présenter la problématique sur laquelle nous avons travaillé, les différentes ressources matérielles et logiciels que nous avons utilisé, les différentes expérimentations réalisées, et enfin on terminera par une discussion des résultats d'évaluation obtenus.

III.2 PROBLEMATIQUE ETUDIEE

Le présent travail s'intéresse à la détection de kératocône (KC). En utilisant les techniques du Deep Learning et plus précisément les CNNs vus dans le chapitre deux (02).

III.3 CONFIGURATION UTILISE DANS L'IMPLEMENTATION

III.3.1 Ordinateur

Pour mener ce travail, on utilise un ordinateur portable avec les caractéristiques suivantes :

- Pc portable :(HP 250) Intel(R) Core (TM) i3-3630M CPU @ 2.30GHZ
- RAM: 4.00 Go
- Carte graphique : Intel (R) HD Graphics 3000
- Disque dure : de taille 500 GO
- Système d'exploitation : Windows 7 64 bits

III.3.2 Langage de programmation

On a utilisé le langage Matlab pour mettre en œuvre notre application.

MATLAB_ (Matrix LABORatory) est un logiciel interactif basé sur le calcul matriciel (permet de manipuler des matrices). Il est utilisé dans les calculs scientifiques

et les problèmes d'ingénierie parce qu'il permet de résoudre des problèmes numériques complexes en moins de temps requis par les langages de programmation courant, et ce grâce à une multitude de fonctions intégrées et à plusieurs programmes outils testés et regroupés selon usage dans des dossiers appelés boîtes à outils ou "toolbox".

Son objectif, par rapport aux autres langages, est de simplifier au maximum la transcription en langage informatique d'un problème mathématique, en utilisant une écriture la plus proche possible du langage naturel scientifique [34].

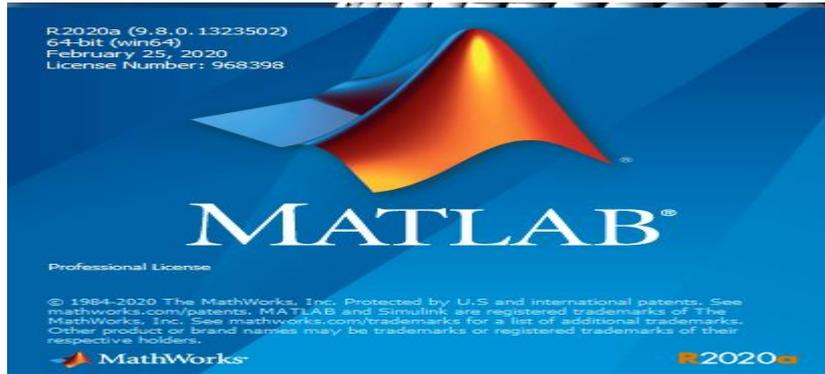


Figure III.1. Interface MATLAB

III.3.3 Présentation de la base de données

La base de données d'images que nous avons utilisée est été sélectionnée par la Clinique Lazouni de Tlemcen à l'ouest d'Algérie. Ou en téléchargement sur Google Drive (Fichier volumineux de 153 Mo (161 440 771 octets)). La BDD est constituée de (274) patients, pour chaque patient nous avons prenons les paramètres de l'œil gauche(OS) et l'œil droit(OD).

	Cas	
	Normal	Kératocône
Sexe		
Homme	69	18
Femme	152	35

Tableau III:1 Répartition des patients dans la BDD

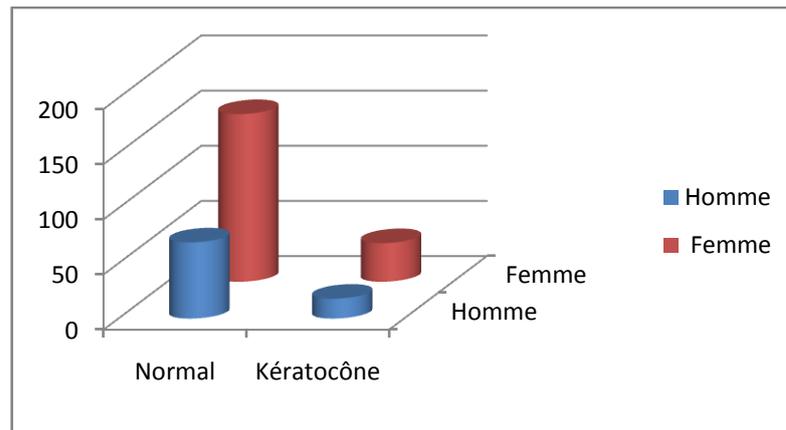


Figure III.2. Histogramme de Statistiques du kératocône

Cette base a été fournie par DR LAZZOUNI. Elle contient 2237 images couleur (RGB) chaque image est sous format (JPEG) ses images sont répartie en 2 classes (normal et kératocône). Dans cette base on trouve 1440 images pour l'apprentissage et 797 images pour le test.

III.3.3.1 Exemples des images contenues dans la BDD (BDD images)

Pour les cas normal et les cas ont le kératocône : on a 8 images, 4 images pour l'œil gauche (OS) et 4 pour l'œil droite (OD).

À partir des figures (III : 3) et (III :4) on remarque qu'il existe 4 blocs (paramètres) différents ce qu'on appelle «Quadmap » :

- la coupe antérieure de la topographie cornéenne.
- la coupe postérieure de la topographie cornéenne de l'œil gauche.
- la kératométrie axiale.
- la pachymétrie.

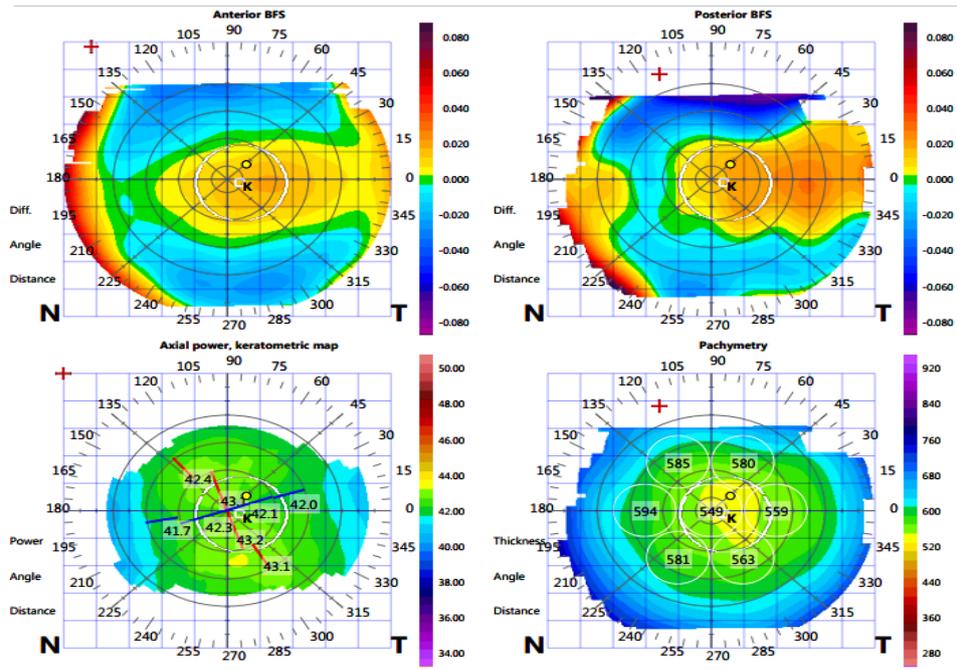


Figure III.3. Carte topographique de l'œil gauche d'un cas normal

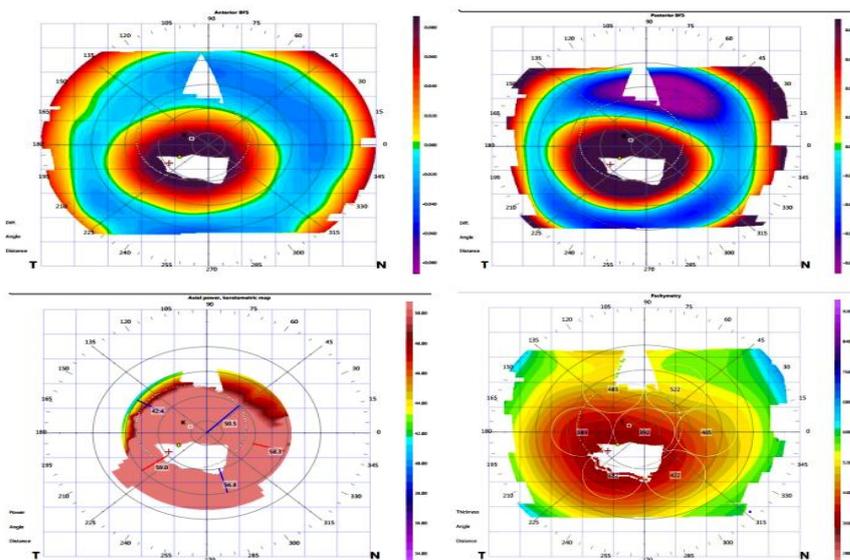


Figure III.4. Carte topographique d'un cas atteint du kératocône

III.4 PRE TRAITEMENT DES DONNEES

Avant l'entraînement du réseau on doit passer par une étape importante qui est le découpage de bases de données (qui peut être aléatoire ou pas) dans deux dossier [Train, Test], 70% pour l'apprentissage et 30% pour le test.

Le nombre de cas dans la base d'apprentissage et de test est présenté dans le tableau suivant:

	Test	Train
kératocône	177	220
normal	620	1220

Tableau III:2 Répartition des cas dans la bases de données

Chargement des données

La base d'images est répartie selon 2 classe dans deux dossiers [Train, Test], il existe une commande sur Matlab qui nous permet de lire ces dossier est «imageDatastore».

III.5 ARCHITECTURE DE NOTRE RESEAU

Au cours de nos expérimentations, nous avons utilisé deux modèles :

- Modèle 01 : avec CNN simple avec des architectures différentes (SGDM, RMSPROP, ADAM).
- Modèle 02 : nous avons créé avec une architecture différente. Ce modèle est basé sur l'architecture Alexnet.

La compilation des deux modèles prend trois paramètres : optimiseur, perte et métriques.

➤ L'optimiseur contrôle le taux d'apprentissage. Toolbox TMoffre plusieurs choix d'optimiseurs : SGDM, RMSPROP, ADAM.

- **SGDM** (Stochastic gradient descent with momentum): est une extension de la méthode de descente gradient qui est utilisée pour le taux de convergence plus rapide de la fonction d'erreur. Dans la méthode de descente de gradient stochastique conventionnelle, seuls les gradients de courant sont

calculée set tandis que dans SGDM, les gradients précédents et actuels sont pris en compte.

- **RMSProp** (Root Mean Square Propagation): est similaire au gradient stochastique au lieu de la façon de calculer le gradient. Il met à jour le taux d'apprentissage en fonction du premier moment moyen du gradient.

-**ADAM** (Adaptive moment estimation):L'optimiseur ADAM calcule le taux d'apprentissage adaptatif individuel pour le paramètre de différentiel à partir du premier et du deuxième moment du gradient .De plus, il est préféré car il peut gérer le gradient bruyant ou clairsemé [35].

Métriques d'évaluation

Commençons par comprendre la terminologie de base utilisée dans les problèmes de classification avant de définir les différentes métriques d'évaluation.

Soit un problème de classification binaire. On représente les deux classes par : {X} et {Non X}. (Exemple : {X} : Hémorragique, {Non X} : Non Hémorragique). On appellera alors :

- True Positif (TP) : un échantillon de {X} prédit comme appartenant à {X}.
- True Négatif (TN) : un échantillon de {Non X} prédit de {Non X}.
- False Positif (FP) : un échantillon de {Non X} prédit de {X}.
- False Négatif (FN) : un échantillon de {X} prédit de {Non X}.

III.5.1.1 Rappel ou sensibilité ou TPR (True Positive Rate)

Nombre d'éléments correctement identifiés comme positifs sur le total des vrais positifs.

$$TPR = TP / (TP + FN)$$

III.5.1.2 Spécificité ou TNR (True Negative Rate)

Nombre d'éléments correctement identifiés comme négatifs sur le total des négatifs.

$$TNR = TN / (TN + FP)$$

III.5.1.3 Précision

Nombre d'éléments correctement identifiés comme positifs sur le nombre total d'éléments identifiés comme positifs.

$$Précision = TP / (TP + FP)$$

III.5.2 Matrice de confusion

Les paramètres définis plus haut permettent de poser la matrice de confusion, comme montré dans la figure (FigI II.5) ci-dessous :

		Actual = Yes	Actual = No
Predicted = Yes		TP	FP
Predicted = No		FN	TN

Figure III.5. Matrice de confusion [7]

III.6 ENTRAÎNEMENT DU MODELE

Nous faisons une comparaison entre trois types d'algorithmes d'optimisation : « SGDM », « ADAM » et « RMSPROP ». Nous cherchons à améliorer les résultats de l'entraînement. Pour le faire nous allons changer les options de l'apprentissage qui sont « *MiniBatchSize* » et « *MaxEpochs* ».

- **Epochs** : C'est le nombre d'époques pour lesquelles nous voulons entraîner notre modèle. Une époque, correspond à un seul passage en entier de nos données de formation à travers le réseau neuronal.

- **MaxEpochs** C'est le nombre maximal d'époques à utiliser pour l'apprentissage.

- **Le BatchSize**: C'est un hyperparamètre de gradient descente ; le nombre total d'entraînements présents dans un seul Batch.

III.7 RESULTAT DU MODELE 01 (CNN)

Les résultats obtenus après la modification des options de l'apprentissage.

1-L'évolution de l'**accuracy** et de la fonction **perte** pour MaxEpochs = [10] et BatchSize =16 est présenté dans les Figures (III .6, III .7 et III .8).

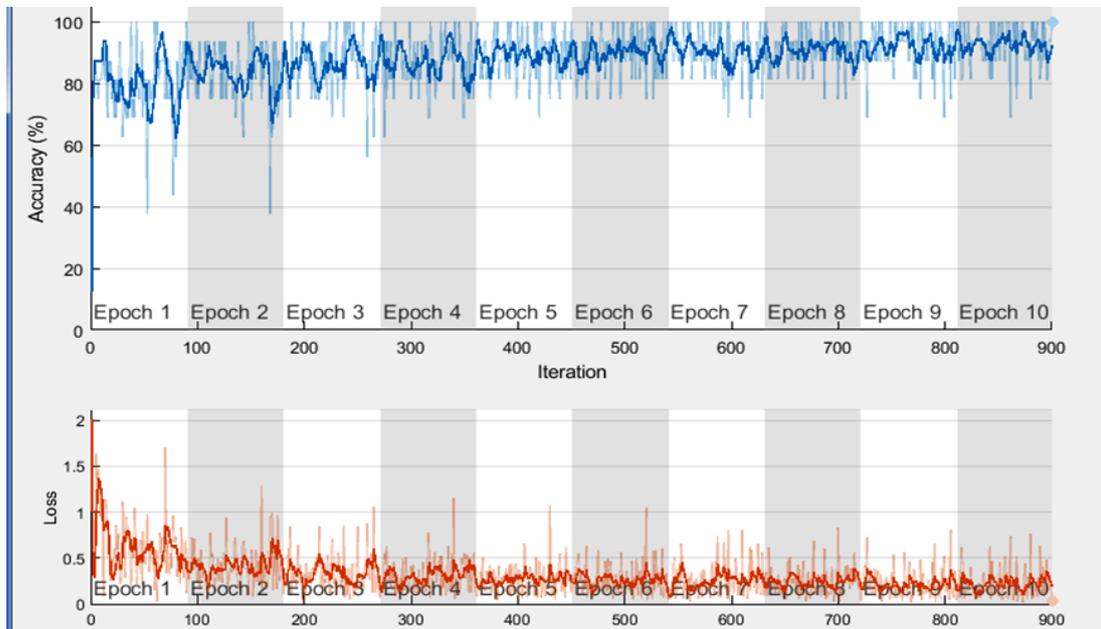


Figure III.6.Apprentissage par la fonction ADAM pour MaxEpochs=10

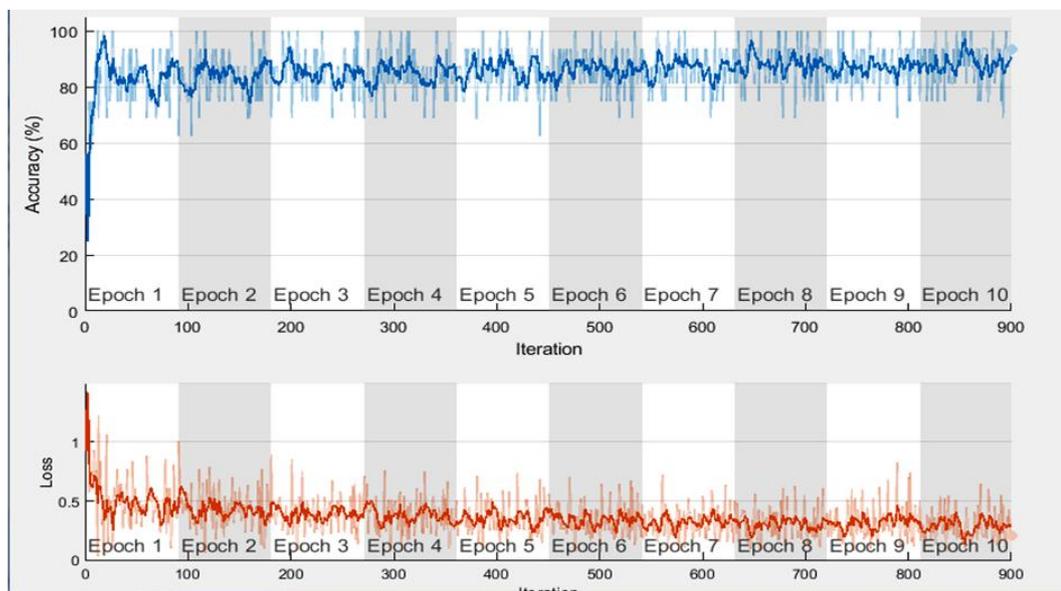


Figure III.7.Apprentissage par la fonction SGDM pour MaxEpochs=10

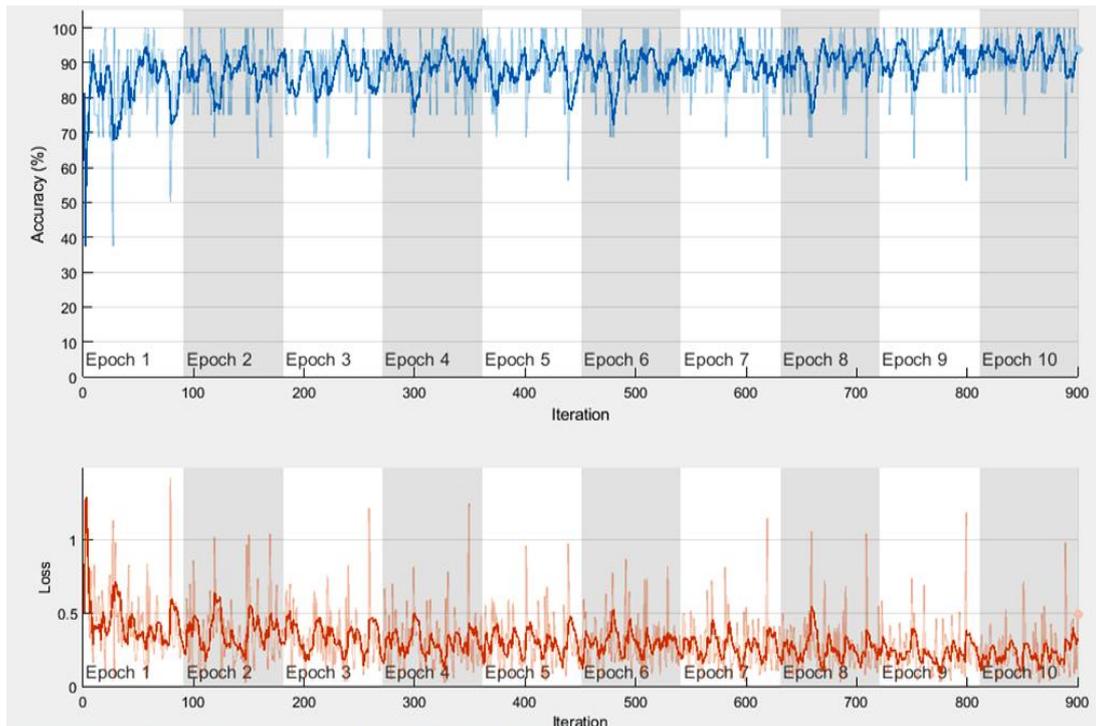


Figure III.8. Apprentissage par la fonction RMSprop pour MaxEpochs=10

- 2- L'évolution de l'**accuracy** et de la fonction **perte** pour MaxEpochs = [20] et BatchSize = 16 est présenté dans les figures (III.9, III.10 et III.11).

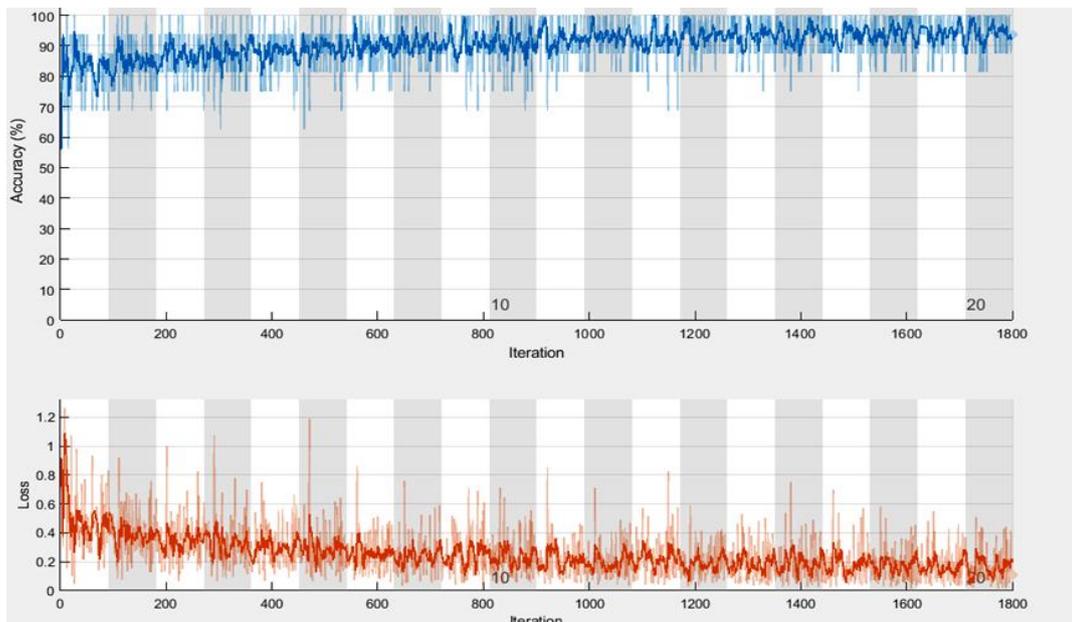


Figure III.9. Apprentissage par la fonction ADAM pour MaxEpochs=20

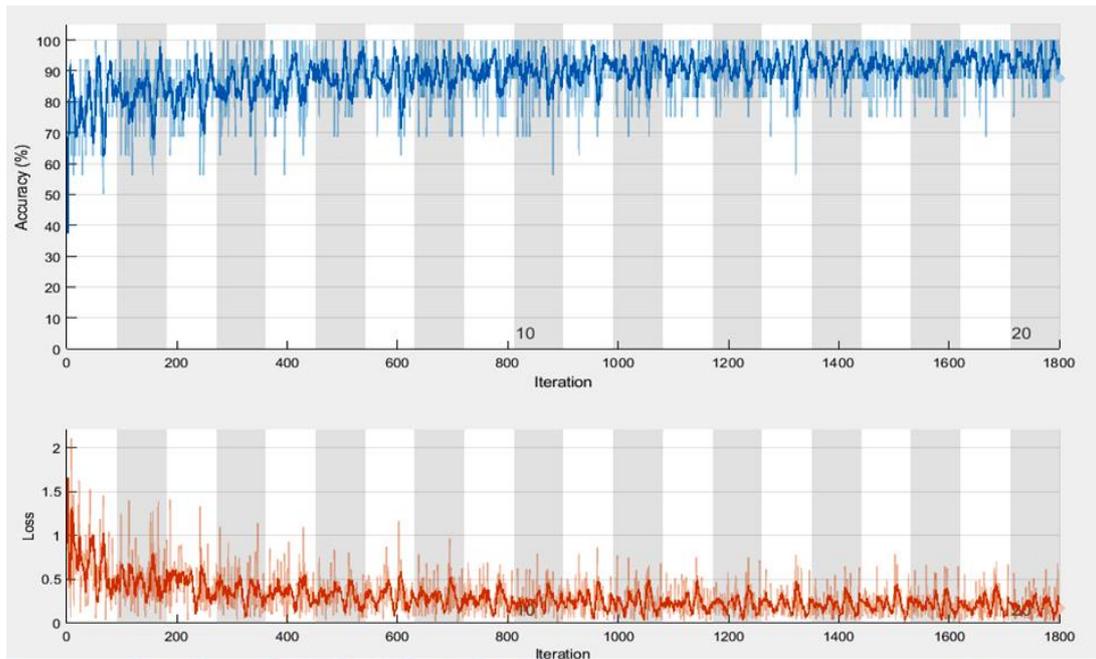


Figure III.10.Apprentissage par la fonction SGDM pour MaxEpochs=20

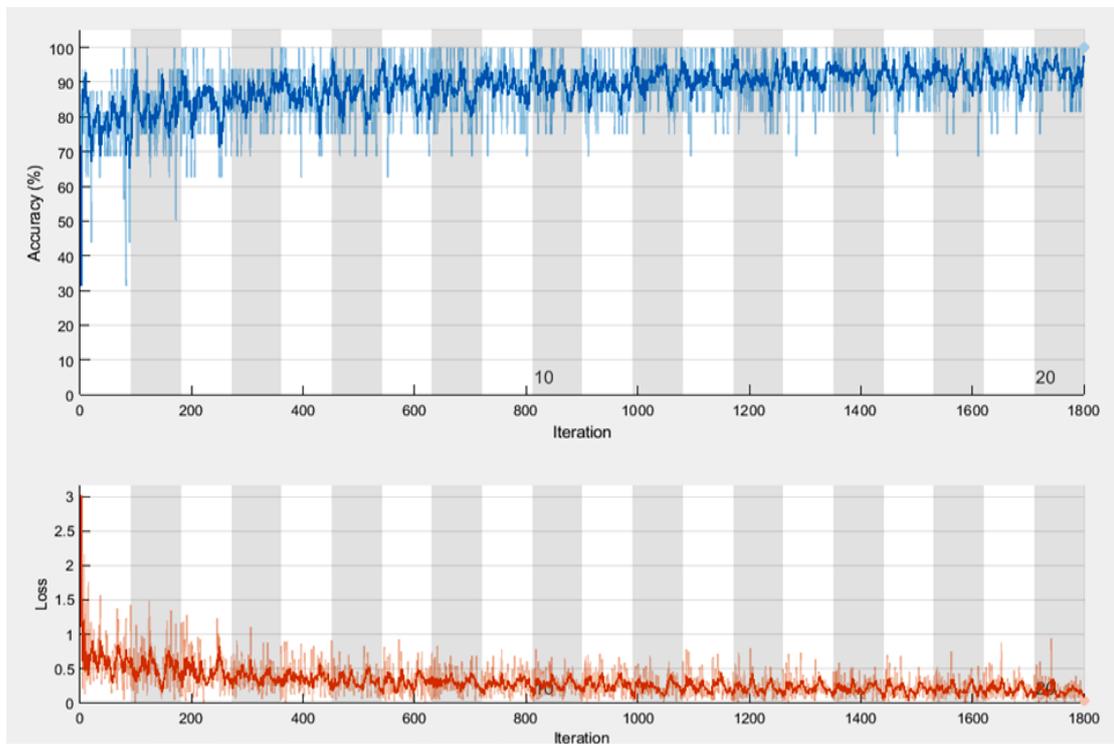


Figure III.11.Apprentissage par la fonction RMsprop pour MaxEpochs=20

3-L'évolution de l'**accuracy** et de la fonction **perte** pour MaxEpochs = [30] et BatchSize = 16 est présenté dans les figures (III.12, III.13 et III .14).

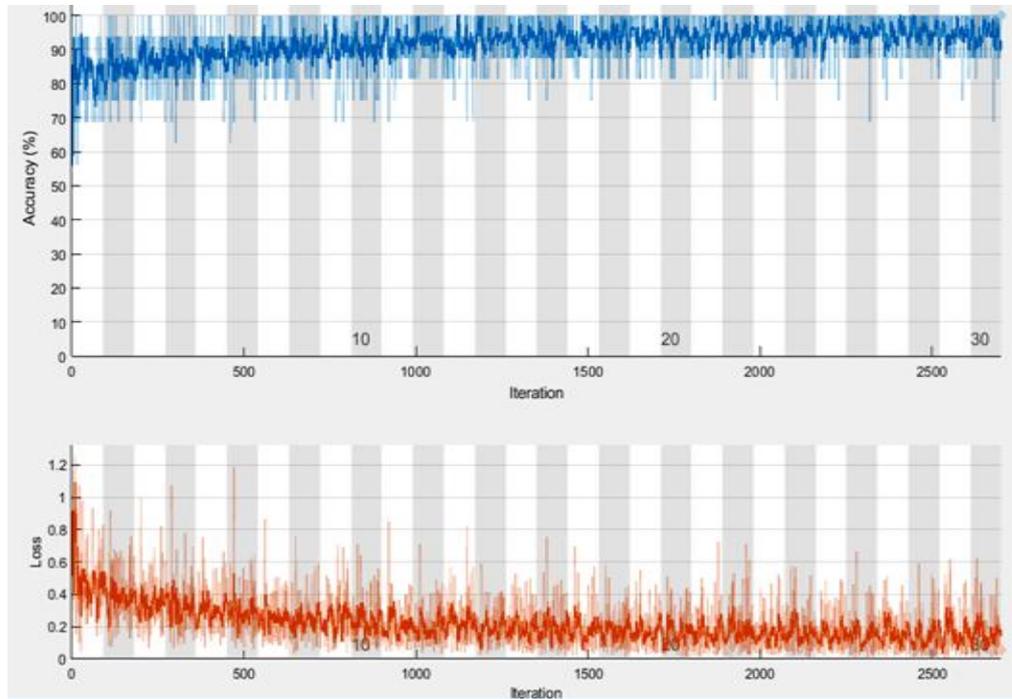


Figure III.12.Apprentissage par la fonction ADAM pour MaxEpochs=30

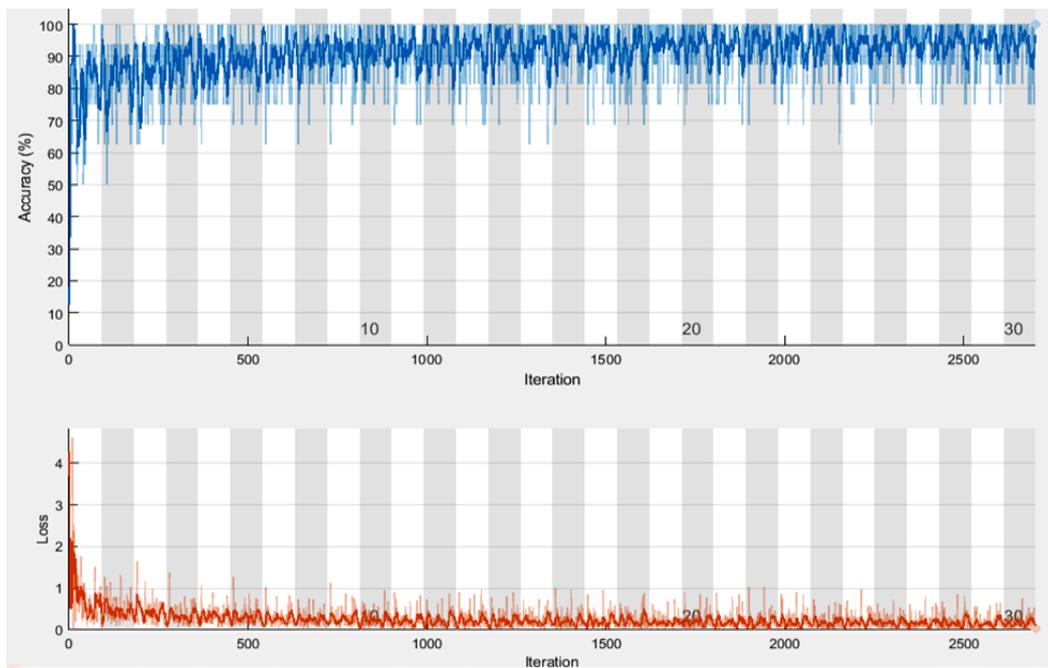


Figure III.13.Apprentissage par la fonction SGDM pour MaxEpochs=30

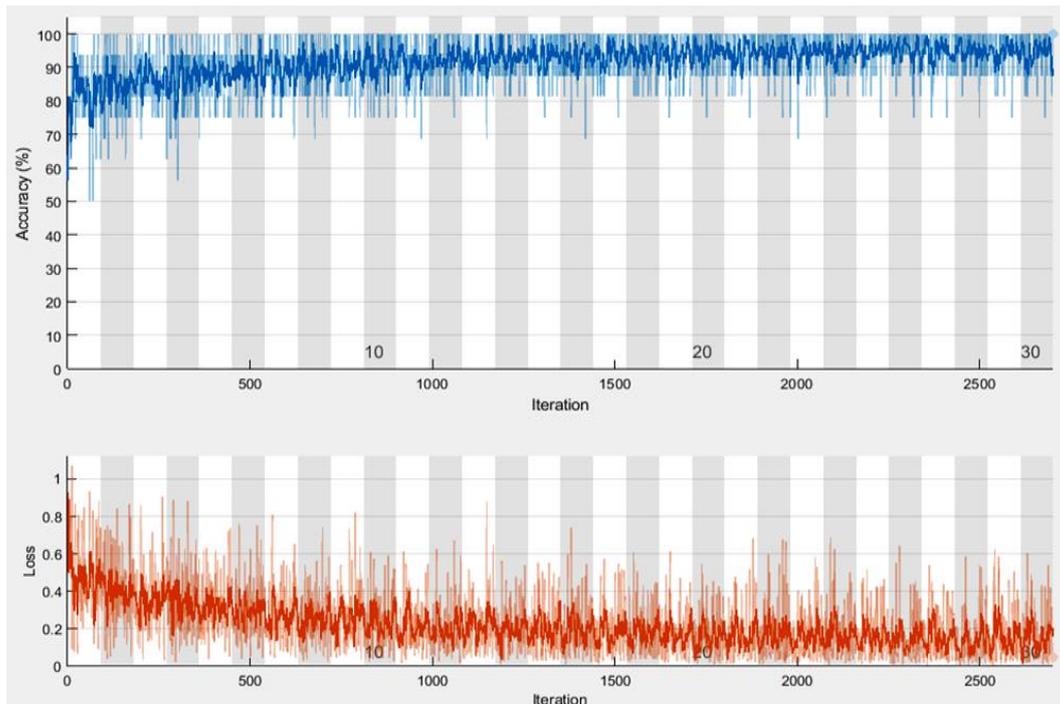


Figure III.14. Apprentissage par la fonction RMSprop pour MaxEpochs=30

On fixe le nombre d'itération (**MaxEpochs**) et on fait varier le **BatchSize**.

1 - L'évolution de l'**accuracy** et de la fonction **perte** pour MaxEpochs = [10] et BatchSize = 32 est présenté dans les figures (III .15, III .16 et III .17).

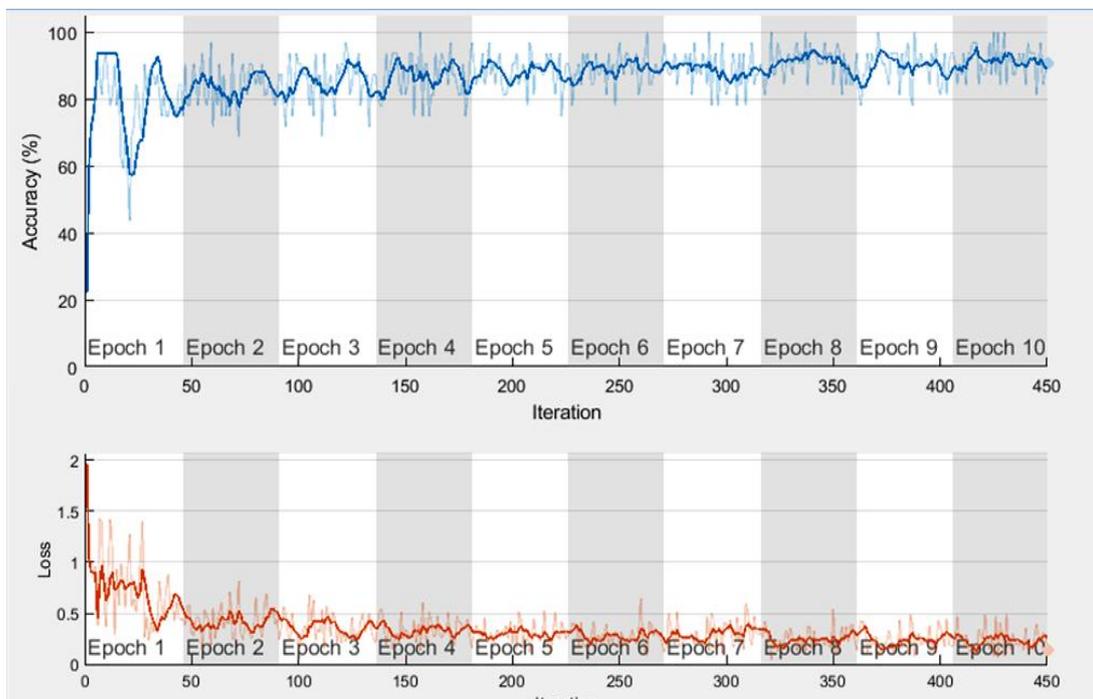


Figure III.15. Apprentissage par la fonction ADAM pour MaxEpochs=10

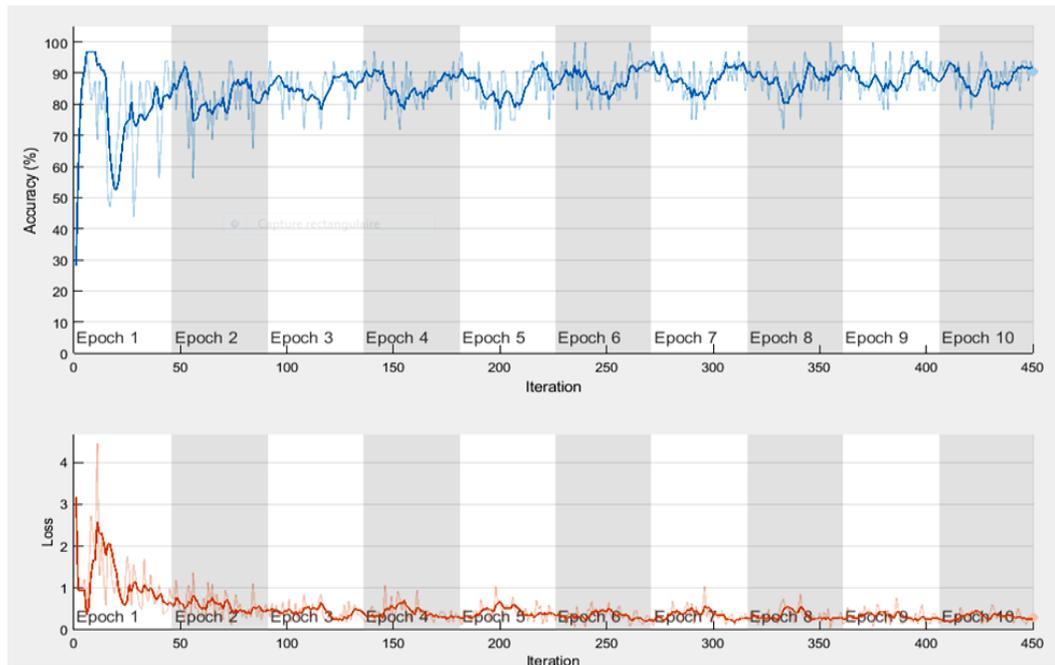


Figure III.16.Apprentissage par la fonction SGDM pour MaxEpochs=10

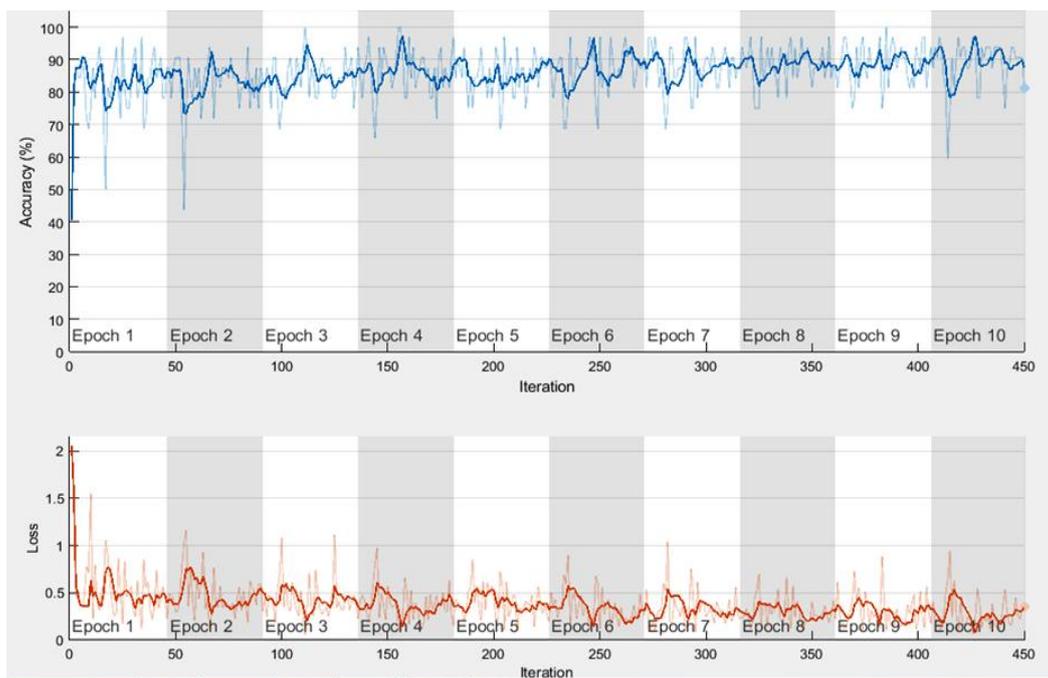


Figure III.17.Apprentissage par la fonction RMSprop pour MaxEpochs=10

2-L'évolution l'accuracy et de la fonction perte pour MaxEpochs= [10] et BatchSize = 64 est présenté dans les figures (III .18, III .19 et III .20).

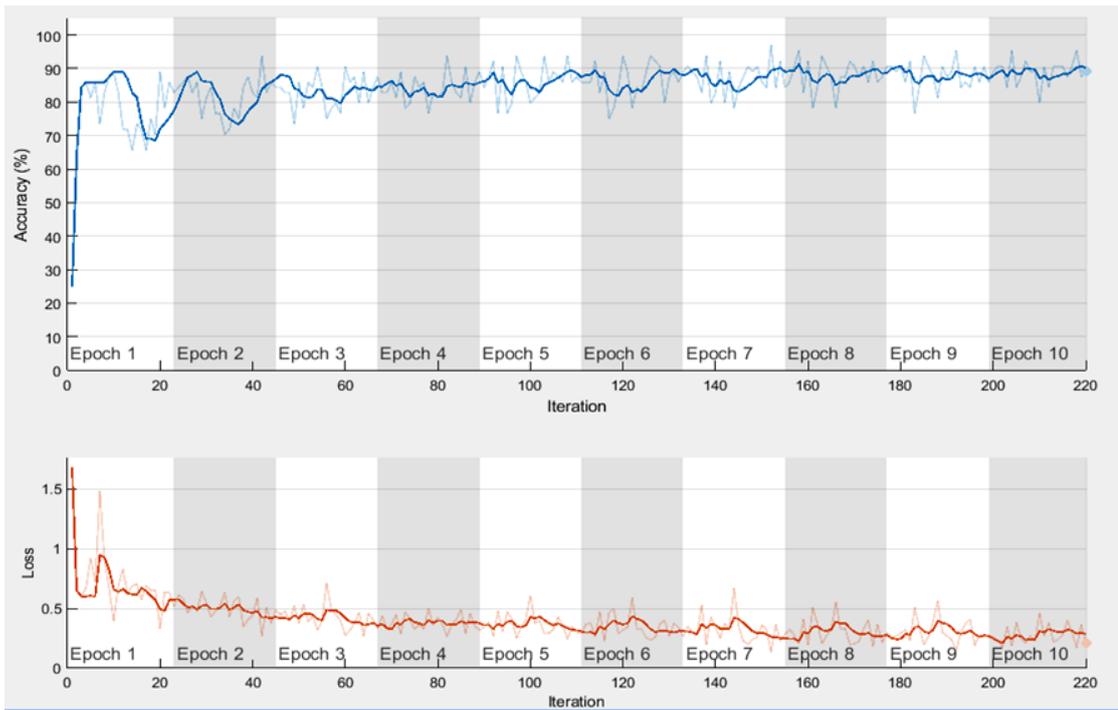


Figure III.18. Apprentissage par la fonction ADAM pour MaxEpochs=10

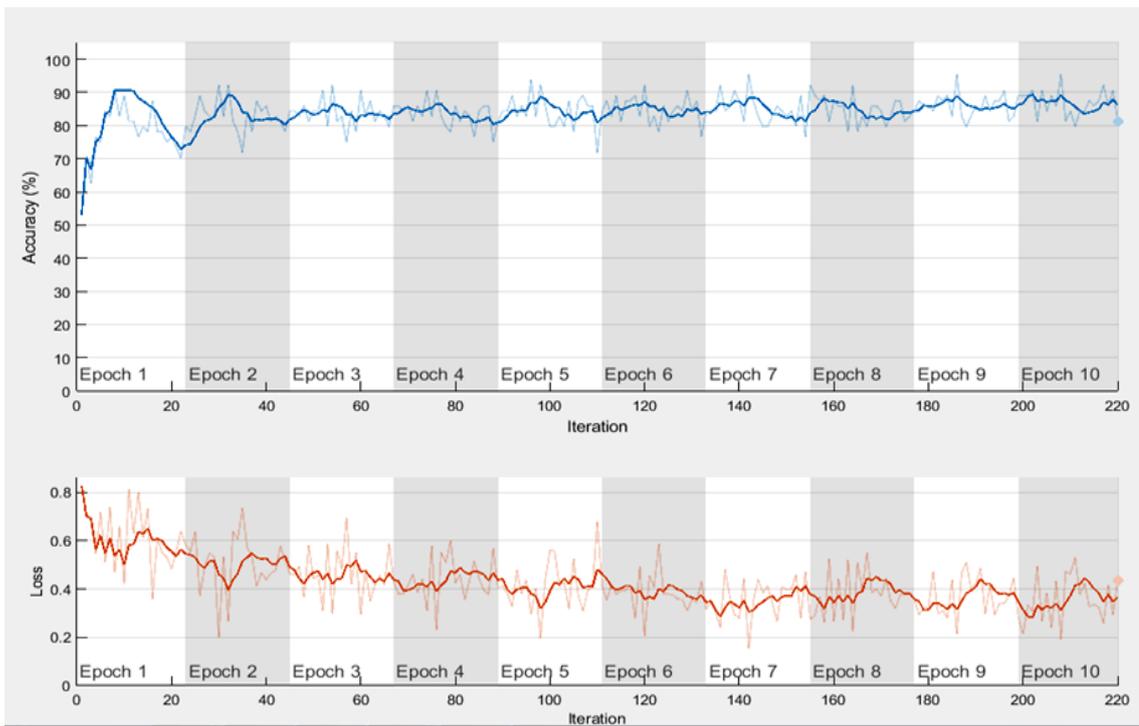


Figure III.19. Apprentissage par la fonction SGDM pour MaxEpochs=10

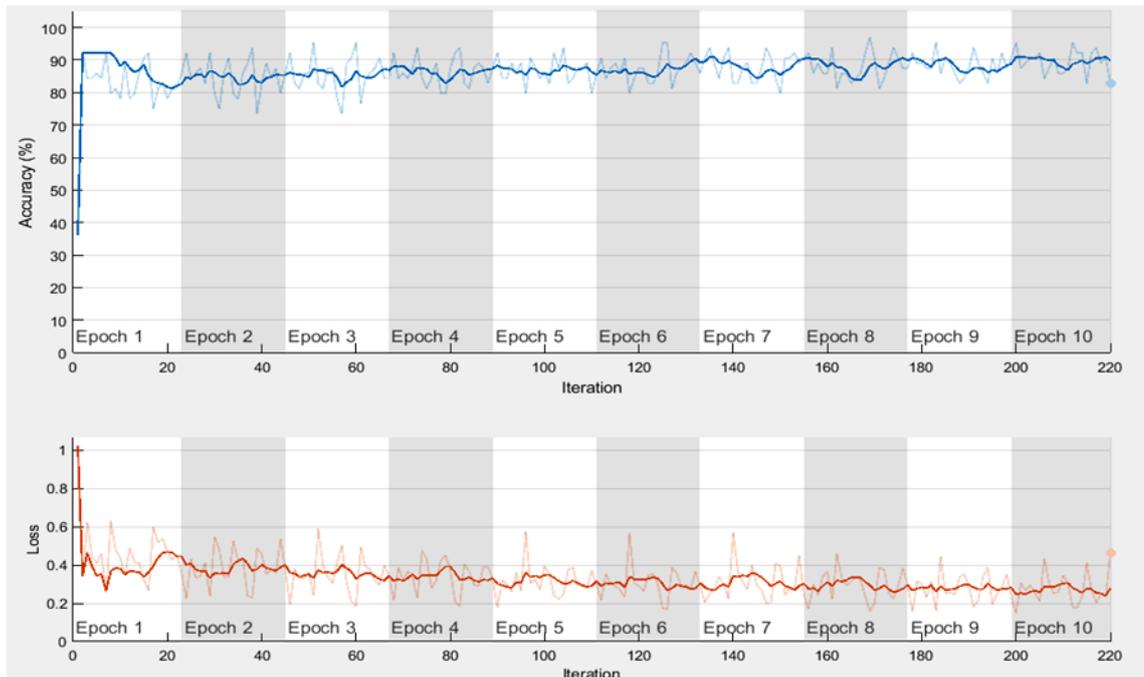


Figure III.20. Apprentissage par la fonction RMSprop pour MaxEpochs=10

- Le paramètre d'accuracy est représenté sur les figures, lorsque le nombre d'époch varie. Ce paramètre représente le nombre de cas correctement détecté.

Nous avons évalué les 2 classes en utilisant les paramètres suivants:

La sensibilité (Se(%)) : ce paramètre représente le taux de classification des cas kc (détectés correctement par le classifieur) par rapport au nombre total des cas kc réels.

$$Se = VP / (VP+FN)*100$$

La spécificité (Sp(%)) : la spécificité indique le taux de classification des cas normal (détectés correctement par le classifieur) par rapport au nombre total du normal réel.

$$Sp = VN / (VN+FP)*100$$

La précision (prec(%)) : représente le taux de classification des cas kc correctement reconnus par le classifieur par rapport au nombre total des cas kc détectés par le classifieur.

$$Préc = VP / (FP+VP)*100$$

Le taux de classification (Tc(%)) : représente le taux de classification total.

$$TC = (VN+VP) / (VN+FN+VP+FP) * 100$$

-Ci-dessous un tableau (Tab III : 3) récapitulatif des différents résultats de formation de CNN. On varie dans le nombre maximal d'époques (10, 20,30) et optimiseur (Adam, Sgdm, Rmsprop) on garde fixe le BatchSize= 16.

CNN SIMPLE						
MaxEpochs	TrainingOptions"Sgdm"		TrainingOptions"Adam"		TrainingOptions"Rmsprop"	
10	MiniBatchSize=16		MiniBatchSize=16		MiniBatchSize=16	
	Accuracy (%)	86.2	Accuracy (%)	91.5	Accuracy (%)	92.2
	Précision (%)	83.8	Précision (%)	96.6	Précision (%)	89.7
	sensibilité (%)	46.9	sensibilité (%)	63.8	sensibilité (%)	73.4
	spécificité (%)	97.4	spécificité (%)	99.4	spécificité (%)	97.6
	VPN	86.5	VPN	90.6	VPN	92.8
20	Accuracy (%)	89.7	Accuracy (%)	94.1	Accuracy (%)	91.7
	Précision (%)	94.4	Précision (%)	91.7	Précision (%)	99.1
	sensibilité (%)	57.1	sensibilité (%)	80.8	sensibilité (%)	63.3
	spécificité (%)	99	spécificité (%)	97.9	spécificité (%)	99.8
	VPN	89	VPN	94.7	VPN	90.5
30	Accuracy (%)	91.2	Accuracy (%)	93.7	Accuracy (%)	94.9
	Précision (%)	74.4	Précision (%)	97.7	Précision (%)	97.2
	sensibilité (%)	92.1	sensibilité (%)	73.4	sensibilité (%)	79.1
	Spécificité (%)	91	Spécificité (%)	99.5	Spécificité (%)	99.4
	VPN	97.6	VPN	92.5	VPN	94.3

Tableau III:3 Tableau comparatif des résultats obtenus pour BatchSize=16

Pour cette configuration : (modèle=SGDM, MaxEpochs= 30), donne les meilleurs résultats avec un TC = 91.2% et une sensibilité =92.1%.

Les résultats obtenus avec Batch Size à 32 sont représentés dans le tableau III.4

CNN						
SIMPLE						
MaxEpochs	TrainingOptions"Sgdm"		TrainingOptions"Adam"		TrainingOptions"Rmsprop"	
	MiniBatchSize=32		MiniBatchSize=32		MiniBatchSize=32	
10	Accuracy (%)	88	Accuracy (%)	92.3	Accuracy (%)	91.8
	Précision (%)	73.7	Précision (%)	87.2	Precision (%)	87.8
	sensibilité (%)	71.2	sensibilité (%)	76.8	sensibilité (%)	73.4
	spécificité (%)	92.7	spécificité (%)	96.8	spécificité (%)	97.1
	VPN	91.9	VPN	93.6	VPN	92.8
20	Accuracy (%)	88.6	Accuracy (%)	91.2	Accuracy (%)	92.5
	Précision (%)	97.8	Précision (%)	87.9	Précision (%)	96.1
	sensibilité (%)	49.7	sensibilité (%)	70.01	sensibilité (%)	68.9
	spécificité (%)	99.7	spécificité (%)	97.3	spécificité (%)	99
	VPN	87.4	VPN	91.9	VPN	95.1
30	Accuracy (%)	91	Accuracy (%)	94.7	Accuracy (%)	94.9
	Précision (%)	83.9	Précision (%)	89.5	Précision (%)	97.9
	sensibilité (%)	73.4	sensibilité (%)	86.4	sensibilité (%)	78.5
	spécificité (%)	96	spécificité (%)	97.1	spécificité (%)	99.7
	VPN	92.7	VPN	96.2	VPN	94.2

Tableau III:4 Tableau comparatif des résultats obtenus pour BatchSize=32

Dans cette configuration, nous avons obtenu un TC= 94.7%, et une sensibilité =86.4% avec la fonction « Adam ».

-Pour confirmer que l'optimiseur « **Rmsprop** » est celui qui donne les meilleures performances, on garde la même configuration et on augmente seulement le BatchSize à **64**.

On obtient les résultats suivants, ci-dessous du tableau (Tab III : 5) récapitulatif des différents résultats de formation de CNN.

CNN						
SIMPLE						
MaxEpochs	TrainingOptions"Sgdm"		TrainingOptions"Adam"		TrainingOptions"Rmsprop"	
10	MiniBatchSize=64		MiniBatchSize=64		MiniBatchSize=64	
	Accuracy (%)	83.7	Accuracy (%)	87.6	Accuracy (%)	88.3
	Précision (%)	64.8	Précision (%)	86.1	Précision (%)	77.3
	sensibilité (%)	58	sensibilité (%)	52.5	sensibilité (%)	67.2
	spécificité (%)	91	spécificité (%)	97.6	spécificité (%)	94.4
	VPN	88.4	VPN	87.8	VPN	91
20	Accuracy (%)	85.1	Accuracy (%)	88.8	Accuracy (%)	91.5
	Précision (%)	75.4	Précision (%)	86.1	Précision (%)	79.5
	sensibilité (%)	48.6	sensibilité (%)	59.3	sensibilité (%)	83.1
	spécificité (%)	95.5	spécificité (%)	97.3	spécificité (%)	93.9
	VPN	85.1	VPN	89.3	VPN	95.1
30	Accuracy (%)	87.8	Accuracy (%)	93	Accuracy (%)	91.5
	Précision (%)	81.3	Précision (%)	89	Précision (%)	95.8
	sensibilité (%)	58.8	sensibilité (%)	78	sensibilité (%)	64.4
	spécificité (%)	96.1	spécificité (%)	97.3	spécificité (%)	99.2
	VPN	89.1	VPN	93.9	VPN	90.7

Tableau III:5 Tableau comparatif des résultats obtenus pour BatchSize=64

III.7.1 Discussion

Après l'analyse des résultats obtenus, on constate les remarques suivant :

- D'après les figures de training on voit qu'à chaque fois quand on augmente le nombre d'epoch le taux de classification (accuracy), VPN, la spécificité et la sensibilité augmentent.
- Quand l'epoch augmente (\uparrow) la fonction loss diminue (\downarrow).

[MiniBatchSize=16] : la fonction « RMsprop » est la plus performante en terme de TC (94.9%) par rapport à la fonction « ADAM » avec un TC=94.1%.

Concernant la sensibilité, « SGDM » donne le meilleur score (92.1%).

[**MiniBatchSize= 32**] : la fonction « ADAM » est la plus performante avec un meilleur TC=94.9% et sensibilité =79.1 %. La fonction « SGDM » meilleurs TC (91%) et sensibilité (73.4%). la fonction « RMsprop », un TC (92.5%) et une sensibilité (68.9%).

[**MiniBatchSize= 64**] : la fonction « RMsprop » est la plus performante à l'époque de (10 et 30) avec TC = 91.5% et une sensibilité de 83.1 %.

D'après les résultats obtenus, la configuration : (modèle=SGDM, MaxEpochs= 30), donne les meilleurs résultats avec un TC = 91.2% et une sensibilité =92.1%.

III.8 RESULTAT DU MODELE 02 (ALEXNET)

On utilise les mêmes options d'entraînements « training Options » de modèle 01 dans ce modèle 02.

-Chargez le réseau neuronal pré-entraîné AlexNet. Si Deep Learning Toolbox™ Modèle pour AlexNet Network n'est pas installé, le logiciel fournit un lien de téléchargement.

III.8.1 Formation, Validation, Résultats et discussions

L'évolution l'**accuracy** et de la fonction **perte** pour MaxEpochs = 10 est présenté dans les figures (III .21, III .22 et III .23).

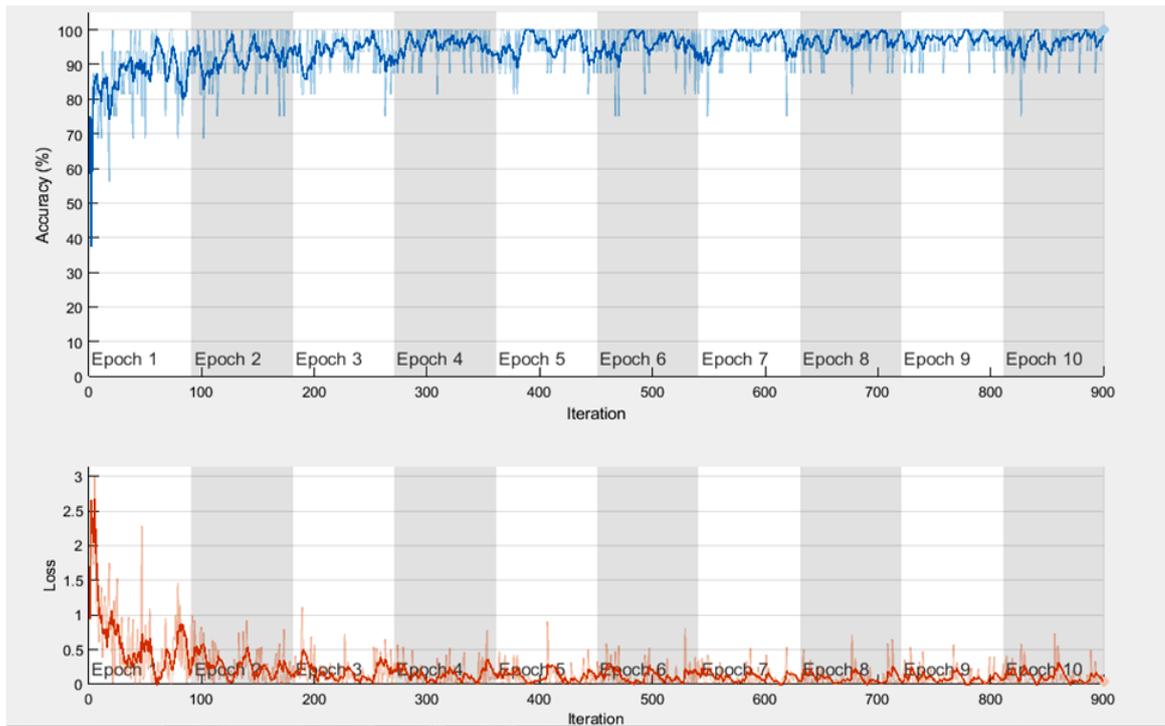


Figure III.21. Apprentissage par la fonction SGDM Option pour MaxEpochs=10

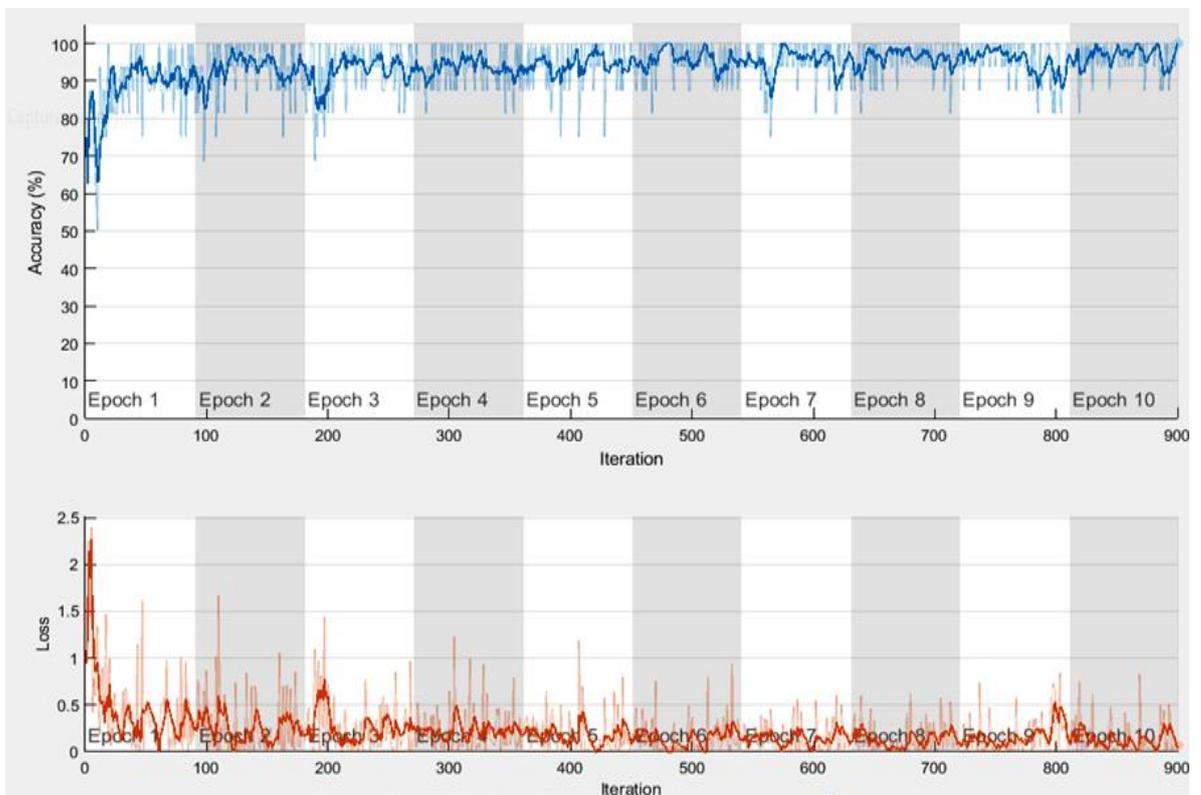


Figure III.22. Apprentissage par la fonction ADAM Option pour MaxEpochs=10

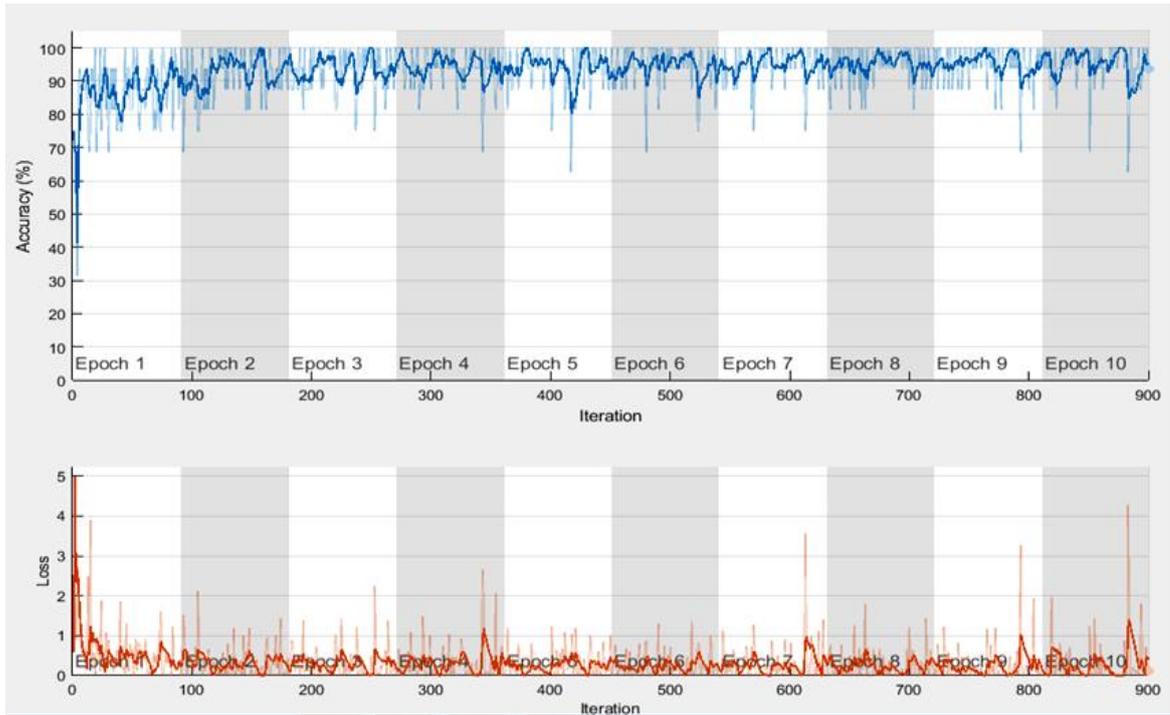


Figure III.23. Apprentissage par la fonction RMSProp Option pour MaxEpochs=10

La matrice de Confusion permet de évaluer les performances de modèle 02 par ce que elle reflète les métriques du Vrais positif, Vrais négatif, Faux positif et Faux négatif, illustrée dans des figures (III.24, III.25 et III .26).

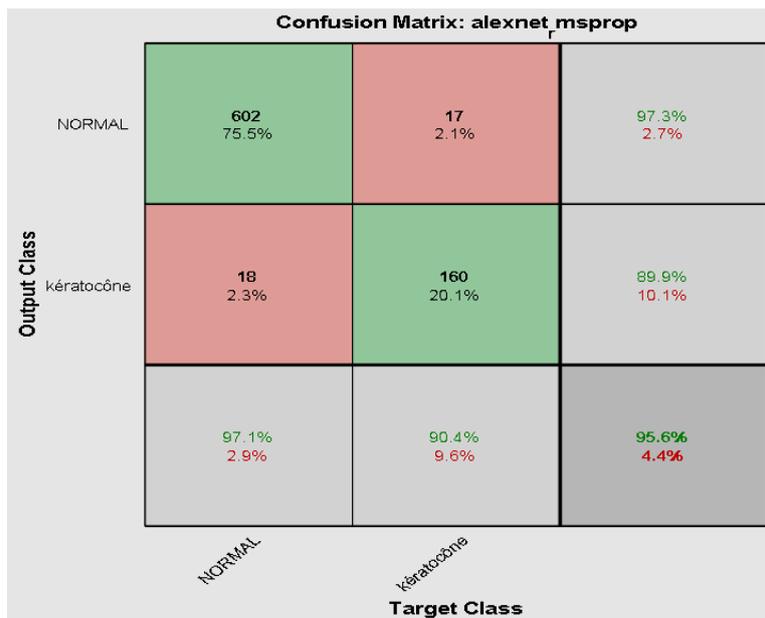


Figure III.24. Matrice de confusion obtenue par la fonction RMsprom pour MaxEpochs=10

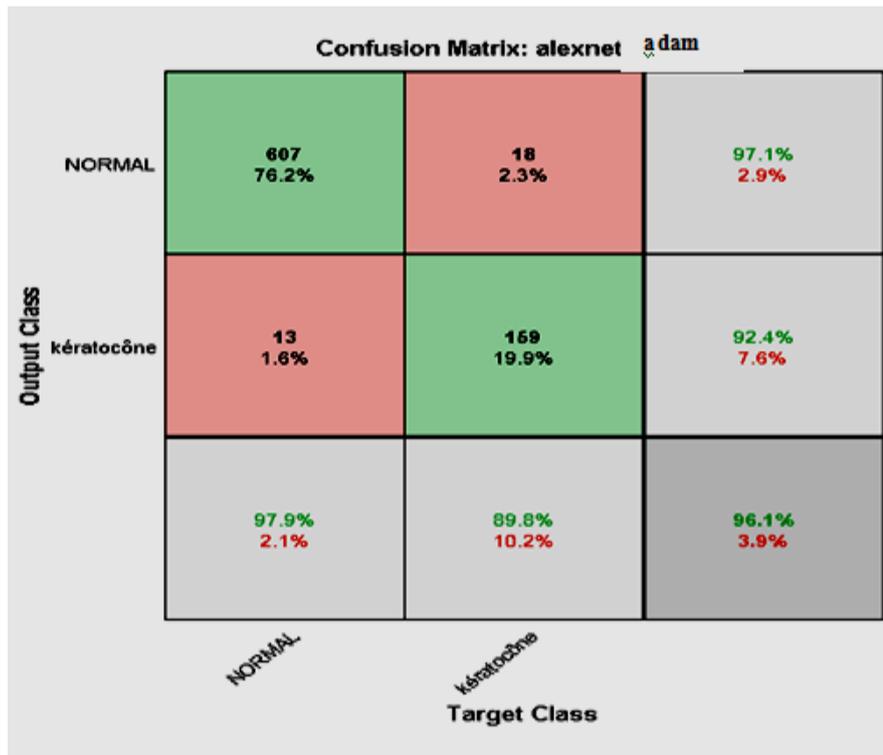


Figure III.25. Matrice de confusion obtenue par la fonction ADAM pour MaxEpochs=10

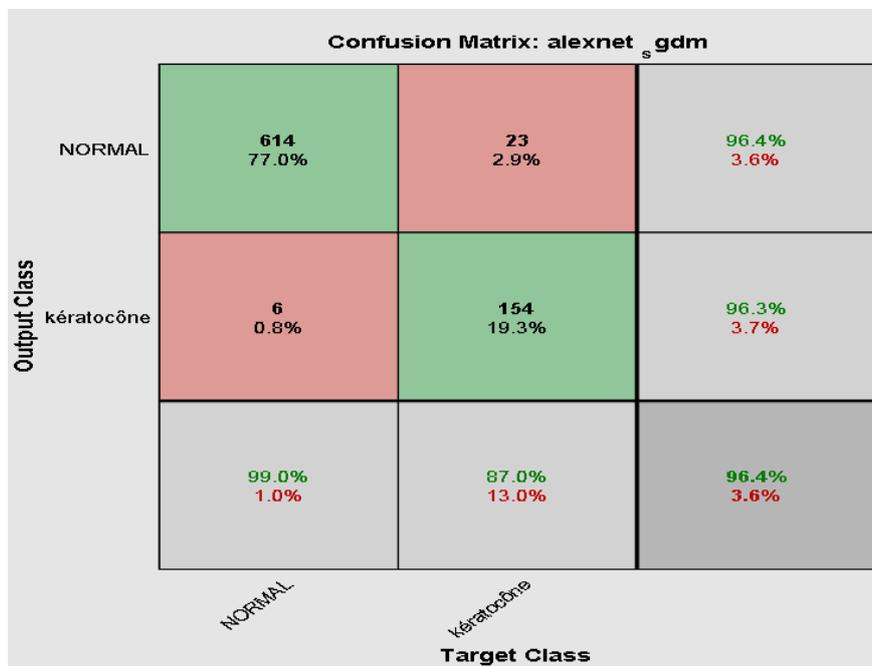


Figure III.26. Matrice de confusion obtenue par la fonction SGDM pour MaxEpochs=10

Les matrices de confusion après normalisation par taille de support de classe (poids) en fonction des éléments de chaque classe. Chaque colonne d'une matrice de confusion représente l'instance d'une classe (kératocône, normal), et chaque ligne représente une classe prédite. Cette matrice montre les taux d'erreur des prédictions par le modèle de classification. Les éléments diagonaux de la matrice représentent le nombre d'images pour lesquelles l'étiquette prédite est égale à l'étiquette réelle, et les éléments restants représentent les images mal étiquetées par le classificateur. Plus les valeurs diagonales d'une matrice de confusion sont élevées, plus les prédictions du modèle sont bonnes.

- Ci-dessous un tableau (TabIII : 6) récapitulatif des différents résultats de formation de modèle pré-entraînés. On varie dans le nombre maximal d'époques (10, 20,30) et optimiseur (Adam, Sgdm, Rmsprop) on fixe le BatchSize= 16

AlexNet						
MaxEpochs	TrainingOptions"Sgdm"		TrainingOptions"Adam"		TrainingOptions"Rmsprop"	
10	MiniBatchSize=16		MiniBatchSize=16		MiniBatchSize=16	
	Accuracy (%)	96.4	Accuracy (%)	96.1	Accuracy (%)	95.6
	Précision (%)	96.3	Précision (%)	92.4	Précision (%)	89.9
	sensibilité (%)	87	sensibilité (%)	89.8	sensibilité (%)	90.4
	spécificité (%)	99	spécificité (%)	97.9	spécificité (%)	97.1
	VPN	96.4	VPN	97.1	VPN	97.3

Tableau III:6 Tableau comparatif des résultats obtenus pour BatchSize=16

Après l'analyse des résultats obtenus, nous avons constaté les remarques suivant :

-Les performances du modèle AlexNet obtenues sur la base d'images est relativement bien (96.4%) avec « Sgdm » et (95.6%) avec « Rmsprop» par rapport à celles obtenus par la fonction « Adam » (96.1%) sur la même de base d'images.

Pour le moment on retient la configuration : (modèle=Alexnet, option =Rmsprop, MaxEpochs=10), qui donne le meilleur résultat avec un Accuracy de 95.6% qui est acceptable, et sensibilité de 90.4%.

En conclusion, la fonction «Rmsprop» est la performante par rapport à les fonctions «Adam» et «Sgdm»

III.9 COMPARAISON DES RESULTATS

Le tableau ci-dessous montre les différents résultats obtenus par les deux modèles :

	CNN_Simple avec SGDM	AlexNet avec RMsprop
MaxEpochs	10	10
MiniBatchSize	16	16
Accuracy (%)	91.2	95.6
Précision (%)	74.4	89.9
sensibilité (%)	92.1	90.4
spécificité (%)	91	97.1
VPN	97.6	97.3

Tableau III:7 Tableau de comparaison de résultats

D'après les résultats obtenus par le modèle 01 « CNN-Simple » et le modèle 02 « AlexNet » sur la même base d'images on remarque que le modèle 02 est le plus performant en terme de TC. Concernant la sensibilité qui représente le taux de classification du Kératocône le premier modèle est le meilleur.

III.10 CONCLUSION

Dans ce chapitre, nous avons fait l'implémentation de deux modèles CNN pour la classification d'image topographie.

Ce modèle a été entraîné et testé avec une BDD local. Enfin nous avons présenté les différents résultats obtenus en termes de taux de classification et la sensibilité. D'après les résultats obtenus par le modèle 01 « CNN-Simple » et le modèle 02 « AlexNet » sur la même base d'images on remarque que le modèle 02 est le plus performant en terme de TC. Concernant la sensibilité qui représente le taux de classification du Kératocône le premier modèle est le meilleur.

CONCLUSION GÉNÉRALE

Conclusion générale

Le kératocône est une courbure qui affecte la cornée et réduit la vision. Il existe plusieurs méthodes pour sa détection précoce. Dans ce projet nous avons utilisé diverses techniques pour la classification des images acquises ; Les images étaient prises à partir de l'examen de topographie cornéenne en utilisant des techniques de classification basées sur les principes de l'apprentissage automatique (ML) et de l'apprentissage profond (DL) à travers neurones convolutifs (CNN) (l'un des algorithmes les plus populaires dans le DL). Afin d'assister le spécialiste dans ce domaine du diagnostic de la maladie.

Dans la partie d'implémentation de ce travail, nous avons présenté les différentes ressources matérielles et les logicielles utilisées.

Ensuite, nous nous sommes concentrés sur l'analyse exploratoire et la mise en forme de nos données. Ensuite, nous avons passé à l'étape de prétraitement des images, pour éventuellement atteindre des bonnes performances à l'étape d'apprentissage et de la classification.

Nous avons commencé à créer, compiler et entraîner les modèles proposés à l'aide des algorithmes « Adam, Rmsprop, et Sgdm ».

Après une analyse des résultats obtenus, le modèle CNN avec la fonction SGDM a été choisi, ce dernier nous a permis d'atteindre une sensibilité de 92.1%.

Comme perspectives, nous proposons de :

- Tester d'autres modèles CNN prédéfinis (VGG, GOOGLE...).
- Utiliser d'autres techniques de sélection de variables.
- La classification de kératocône selon ces quatre stades.
- Algorithme pour l'extraction des régions d'intérêt sur lesquelles s'appuient les médecins pour interpréter la carte topographique du patient (séparer les régions pour avoir uniquement les zones de 3mm, 5mm), et classer les résultats selon le degré de gravité.
- Le calcul du nombre de couleurs dans chaque région étudiée.

BIBLIOGRAPHIE

Bibliographie

- [1] **DR.SENOUCI**, « *L'œil et la physiologie de la vision* »
<http://www.facmed-univ-oran.dz>
- [2] **ASIMELLIS G, KAUFMAN EJ.** “*KERATOCONUS*”
 Treasure Island (FL), Statpearls Publishing; 2021
- [3] **BI KUO, WY CHANG, ET AL**, “*Keratoconus screening based on deep learning approach of corneal topography*”, Vision Science, 2020 -
- [4] **A LAVRIC, P VALENTIN**, “*KeratoDetect: keratoconus detection algorithm using convolutional neural networks*”, Computational intelligence and neuroscience, 2019 - hindawi.com
- [5] **D. GATINEL, A. SAAD**, « *Détection automatisée du kératocône fruste avec l'Orbscan* », Fondation Rothschild, Centre d'Expertise et de Recherche en Optique Clinique (CEROC), 2011.
- [6] **D .GATINEL**, « *Evoquer et dépister un kératocône débutant* »
 Réalités ophtalmologiques. mars, 2013.
- [7] **LAMRI MOHAMED AMINE**, « *Détection et classification des hémorragies intracrâniennes dans les images TDM par le Deep Learning* ». Mémoire de Master, Université M'Hamed Boughara-Boumerdes, 2020.
- [8] **N WAKED, AM FAYAD, ET AL** « *Dépistage du kératocône dans une population universitaire au Liban* » Journal français d'ophtalmologie, 2012, Pages 23-29, Elsevier.
- [9] **SOUKAINA IGHOUER**, « *Le kératocône : Expérience du service d'Ophtalmologie* ». Thèse doctorat. Université Cadi Ayad Faculté de Médecine de Pharmacie, Marrakech, 2017.

- [10] **C. MARTEL**, « *Le kératocône* ». *Association des optométristes du Québec. Clinique optométrique*, 2014. <https://www.keratocone.net>
- [11] **MYRIAM CASSAGNE**, « *Crosslinking trans-épithélial du collagène cornéen: évaluation pré-clinique de l'iontophorèse* ». Thèse doctorat ; Université Toulouse III - Paul Sabatier. 2013.
- [12] **<https://www.keratoconuscanada.org/a-propos-de-la-fondation-canadienne-du-keratocone>**
- [13] **Mous A, MostafiM**, « *Reconnaissance des données kératocône par une méthode intelligente* ». Mémoire de Master. Université de Tlemcen, 2013.
- [14] **Tatiana LUPASCO**, « *Etude comparative du programme de différenciation terminale de l'épithélium de la cornée normale et des patients atteints de kératocône* ». thèse doctorat, Université Toulouse 3 - Paul Sabatier .2019.
- [15] **S GOEBELS, T EPPIG, B SEITZ, ET AL**, “*Detection of early forms of keratoconus - current screening methods*”, 2013 - europepmc.org ,
doi: 10.1055 / s-0032- 1328694 sci-hub.do/10.1055/s-0032-1328694.
- [16] **D. GATINEL**, « *Topographie cornéenne* ». *Fondation Rothschild*, 2014
- [17] **Manjula Kamalahasan**, “*Review on algorithms in image processing*”, 2017, <https://www.researchgate.net/publication/331319583>
- [18] **<https://parsers.me/deep-learning-machine-learning-whats-the-difference/>**
- [19] **BENSLIMANE A. A, KETTEB H**, « *Identification Individuelle De Bovins A Base De Réseaux De Neurones* ». Mémoire de Master, Université Mouloud Mammeri de Tizi-Ouzou.2020.

- [20] **SENANI SAMY**, « *Réseaux de nuerons conventionnels pour la détection précoce de rétinopathie diabétique* », Mémoire de Master , Université Mouloud Mammeri de Tizi-Ouzou ,2019.
- [21] <https://www.oracle.com/fr/cloud/deep-learning-intelligence-artificielle.html>
- [22] **AMMAR MOHAMED**, « *Chapitre 2, Généralités Sur Les Images Numériques* » *Cour De Traitement D'image Numerique*, 2019.
- [23] **C.HOUASSINE**, « *Segmentation D'images Par Une Approche Biomimétique Hybride* ».Université M'Hamed Bougara Boumerdes.2012.
- [24] **BOUKHOBZA.A, KAFI.M**, « *Aide au diagnostic des nodules thyroïdiens par classification de coupes histologiques* » Mémoire de Master ; Université Abou Bakr Belkaïd de Tlemcen.2020.
- [25] **BEMMOUSSAT .N.M, BENAMEUR N**, « *Segmentation du foie par Réseau de Neurones Convolutionnel* ».Mémoire de Master, Université Abou Bakr Belkaïd de Tlemcen. 2019.
- [26] **D. BOUADI, T. IMARAZENE**, « *Classification d'images agricoles avec le Deep Learning* ».Université Mouloud Mammeri, TIZI OUZOU, 2019.
- [27] **AMMAR MOHAMED**, « *Réseaux de Neurones* »*Cour de modélisation et stimulation des systèmes biomédicaux*, 2020.
- [28] **LAZOUNI .M. A**, «*Aide au diagnostic pour un médecin anesthésiste réanimateur* ». Thèse doctorat, Université Abou Bekr Belkaid, 2014.
- [29] **EKABA BISONG**, « *Building Machine Learning And Deep Learning Models On Google Cloud Platform:A Comprehensive Guide For Beginners* ».2019. ISBN-13 (pbk): 978-1-4842-4469-2. <https://doi.org/10.1007/978-1-4842-4470-8>

- [30] **BELHADJER .H, SAROUER .B**, « *Classification Des Images Avec Les Réseaux De Neurones Convolutionnels* ». Mémoire de Master ; Université Mouloud Mammeri de Tizi-Ouzou, 2018.
- [31] **SIDDHARTH DAS**, "CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more". 2017. <https://medium.com>
- [32] **KAIMING HE ET AL**, *Deep Residual Learning for Image Recognition*”, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770-778.
- [33] **PRABHU**, « *CNN Architectures - LeNet, AlexNet, VGG, GoogLeNet et ResNet* »2018, <https://medium.com>
- [34] **BOUGHABA. M, BOUKHRIS.B**, « *L'apprentissage profond pour la classification et la recherche d'images par le contenu* ». Mémoire de Master, Université d'Ouargla 2017.
- [35] **KEBBABI NAIMA**, « *Classification des cellules cytologiques par les réseaux de neurones convolutifs (CNN)* ». Mémoire de Master, Université M'Hamed Boughara-Boumerdes, 2020.