



# MEMOIRE

Présenté par

**OUNNAS Aimane**

Pour l'obtention de diplôme de

**MASTER**

**Filière : Informatique**

**Spécialité : Systèmes Informatiques Intelligents**

**Thème**

**UTILISATION DU DEEP LEARNING POUR  
DETECTER LA RETINOPATHIE  
DIABETIQUE**

**Soutenu le : 25/06/2023**

Devant le jury composé de :

**Mme GASMI Ibtissem**

**MCB**

**Univ.de el tarf**

**Président**

**Mme AHMED MALEK Nada**

**MAA**

**Univ.de el tarf**

**Rapporteur**

**Mme MAKHLOF Amina**

**MAA**

**Univ.de el tarf**

**Examineur**

**Année Universitaire :2022/2023**

# Remerciements

---

Mes remerciements vont tout d'abord à Dieu tout-puissant pour la volonté, la santé et la patience qu'il m'a accordées durant toutes ces années d'études.

En particulier, je tiens à remercier **Mme AHMED MALEK Nada**. Ce projet ne serait pas aussi riche et n'aurait pas pu voir le jour sans son aide et sa supervision. Je la remercie d'avoir accepté d'être mon superviseur durant cette année, pour toute l'aide apportée et pour m'avoir proposé ce sujet, pour la qualité de son encadrement, sa rigueur et sa disponibilité, ses remarques fructueuses et ses orientations précieuses, qui ont effectivement contribué à l'avancement de ce travail.

Je remercie sincèrement :

- **Mme GASMI Ibtissem**, pour m'avoir honoré de présider les jury
- **Mme MAKHLOF Amina**, pour avoir accepté d'examiner ce travail.

Un grand merci aux **PROFESSEURS** de notre département d'informatique en particulier à **M<sup>r</sup>. BETOUIL Abdelatif**, **M<sup>r</sup>. CHEMMAM Chaouki** et **M<sup>r</sup>. BENMACHICHE Abdelmadjid**.

Je suis reconnaissant envers tous les membres de ma famille, plus spécifiquement envers **MES PARENTS**, pour leur soutien constant, leurs encouragements et leur patience tout au long de mes études. J'exprime également ma gratitude envers **mes collègues** pour les précieux moments partagés ensemble.

Je tiens à remercier, mes amis **Haïthem KARROUCHE** et **LAMRI Ahmed Zaki** qui m'ont aidé dans ce travail.

Enfin, je remercie tous ceux qui m'ont aidé de loin ou de près.  
Merci à tous du fond du cœur.

**OUNNAS Aimane**

# Dédicaces

---

Avec un grand cœur plein de chaleur, je dédie ce travail, aux êtres qui sont les plus chers pour moi :

Je tiens à exprimer toute ma gratitude à **ma mère bien-aimée**. Sa tendresse, son soutien inconditionnel et son amour constant ont été une source de réconfort et de force tout au long de mon parcours. Sa présence dans ma vie est un cadeau précieux, et je suis profondément reconnaissant de l'avoir à mes côtés. Je ne pourrais jamais assez la remercier pour tout ce qu'elle a fait et continue de faire pour moi. Je suis rempli d'amour et de reconnaissance envers cette femme exceptionnelle qui est **ma mère**.

Je souhaite exprimer ma profonde gratitude envers **mon cher père** pour sa vigilance constante en ce qui concerne mon éducation, ses encouragements infaillibles et sa contribution à mon parcours d'études dans des conditions optimales. Je suis véritablement reconnaissant d'avoir un père aussi attentionné et dévoué. Son soutien indéfectible a été essentiel pour mon développement académique et personnel. Je lui suis infiniment reconnaissant pour tout ce qu'il a fait pour moi.

À **mes grands frères Farid , Youcef , Bilal et Abdelkarim** qui ont été de bons exemples pour moi et m'ont appris à travailler dur pour les choses auxquelles j'aspire.

À **mes petites frères Ahmed Yacine et Anoir et ma sœur Roumaïssa**, merci d'être les meilleurs frères et sœur que je puisse souhaiter.

À **mes neveux** que je les considère comme mes enfants.

Je souhaite exprimer ma profonde reconnaissance envers **mes chers cousins Abderrahmane et Ishak**, qui ont toujours été présents pour moi et m'ont toujours apporté leur soutien inconditionnel.

À mes amis : **Aboubakeur, Nawri, Mohamed Fouad, Chams Eddine, Zakaria, Aymen, Raed, Taki** pour leur aide et leur soutien.

***OUNNAS Aimane***

# Abstract

*Diabetic retinopathy is recognized as the leading cause of blindness worldwide. However, it is important to highlight that early detection of this condition and appropriate treatment can significantly reduce the risk of vision loss.*

*For this reason, medical authorities recommend annual eye examinations for diabetic patients. This type of examination helps detect early signs of diabetic retinopathy and enables prompt action to avoid serious complications.*

*This thesis explores different artificial intelligence-based approaches for the early detection of diabetic retinopathy. The study focuses on a proposed CNN architecture and aims to evaluate the performance of a standalone CNN model, a standalone SVM model, as well as a hybrid approach combining CNN and SVM with this architecture.*

*The results show that the standalone CNN model demonstrates good accuracy in detecting diabetic retinopathy. Similarly, the standalone SVM model also achieves good performance. However, when combining CNN and SVM, a significant drop in accuracy is observed, raising questions about the effectiveness of this hybrid approach.*

*This finding raises concerns about the reasons behind the decrease in accuracy when combining the two models. Further investigations are necessary to understand the factors that influence the performance of the hybrid approach.*

*In conclusion, this study highlights the importance of continuing research and development of more sophisticated artificial intelligence models to improve the early detection of diabetic retinopathy. Optimizing the hybrid approach and exploring other promising techniques could be future research directions to enhance the detection performance of this pathology.*

**Keywords:** *Diabetic retinopathy; screening; fundus examination; SVM; CNN.*

# Résumé

*La rétinopathie diabétique est reconnue comme étant la principale cause de cécité au niveau mondial. Cependant, il est important de souligner que la détection précoce de cette affection et un traitement approprié peuvent considérablement réduire le risque de perte de la vue.*

*Pour cette raison, les autorités médicales recommandent aux patients diabétiques de subir un examen annuel du fond d'œil. Ce type d'examen permet de détecter les signes précoces de la rétinopathie diabétique et d'agir rapidement pour éviter des complications graves.*

*Ce mémoire de fin d'études explore différentes approches basées sur l'intelligence artificielle pour la détection précoce de la rétinopathie diabétique. L'étude met l'accent sur une architecture CNN proposée et vise à évaluer les performances d'un modèle CNN seul, d'un modèle SVM seul, ainsi que d'une approche hybride combinant CNN et SVM avec cette architecture.*

*Les résultats montrent que le modèle CNN seul présente de bons résultats en termes d'accuracy dans la détection de la rétinopathie diabétique. De même, le modèle SVM seul atteint également de bonnes performances. Cependant, lors de l'hybridation du CNN et du SVM, une chute significative de l'accuracy est observée, remettant en question l'efficacité de cette approche hybride.*

*Cette constatation soulève des interrogations quant aux raisons de la diminution de l'accuracy lors de la combinaison des deux modèles. Des investigations approfondies sont nécessaires pour comprendre les facteurs qui influent sur les performances de l'approche hybride.*

*En conclusion, cette étude met en évidence l'importance de continuer la recherche et le développement de modèles d'intelligence artificielle plus sophistiqués pour améliorer la détection précoce de la rétinopathie diabétique. L'optimisation de l'approche hybride et l'exploration d'autres techniques prometteuses pourraient être des axes de recherche futurs afin d'améliorer les performances de détection de cette pathologie.*

**Mots clés :** *Rétinopathie diabétique ; dépistage ; fond d'œil ; SVM ; CNN.*

## ملخص

التمايز البصري هو السبب الرئيسي للعمى في جميع أنحاء العالم. ومع ذلك، فمن المهم أن نشدد على أن الكشف المبكر عن هذا الاضطراب والعلاج المناسب يمكن أن يقلل بشكل كبير من خطر فقدان البصر.

لهذا السبب، توصي السلطات الطبية بإجراء فحص سنوي للعيون للمرضى السكريين. يساعد هذا النوع من الفحص في اكتشاف علامات مبكرة للتمايز البصري واتخاذ إجراءات سريعة لتجنب المضاعفات الخطيرة.

تستكشف هذه الأطروحة مقاربات مختلفة قائمة على الذكاء الاصطناعي للكشف المبكر عن التمايز البصري. تركز الدراسة منفرد، بالإضافة إلى نهج مختلط *SVM* منفرد ونموذج *CNN* المقترحة وتهدف إلى تقييم أداء نموذج *CNN* على هندسة بهذه الهندسة *SVM* و *CNN* يجمع بين

المستقل يظهر نتائج جيدة من حيث الدقة في اكتشاف التمايز البصري. وبالمثل، يحقق نموذج *CNN* تظهر النتائج أن النموذج، يلاحظ انخفاض ملحوظ في الدقة، مما يثير تساؤلات *SVM* و *CNN* المستقل أيضاً أداء جيداً. ومع ذلك، عند دمج *SVM* حول فعالية هذا النهج المختلط.

تثير هذه النتيجة قلقاً حول الأسباب التي تؤدي إلى انخفاض الدقة عند دمج النموذجين. هناك حاجة لمزيد من البحوث والتحقيقات لفهم العوامل التي تؤثر على أداء النهج المختلط.

في الختام، تسلط هذه الدراسة الضوء على أهمية مواصلة البحث وتطوير نماذج ذكاء اصطناعي أكثر تطوراً لتحسين الكشف المبكر عن التمايز البصري. يمكن أن يكون تحسين النهج المختلط واستكشاف تقنيات أخرى واعدة محاور بحثية مستقبلية لتعزيز أداء الكشف عن هذا الاضطراب.

الكلمات الرئيسية: التمايز البصري، الفحص، فحص أساس العين، *SVM*، *CNN*.

## Table des matières

Remerciements .....	2
Abstract .....	4
Résumé.....	5
ملخص.....	6
Contenu .....	7
Listes des figures.....	11
Listes des tableaux .....	13
Liste des abréviations .....	14
Introduction générale.....	1
Chapitre 1 : Fondements théoriques.....	3
1. Introduction .....	3
2. Le diabète et complications oculaires .....	3
2.1. Définition du diabète.....	3
2.2. Type du diabète : .....	3
2.3. Complications oculaires liées au diabète : .....	4
2.3.1. La cataracte .....	4
2.3.2. Le glaucome .....	4
2.3.3. La rétinopathie diabétique.....	5
3. Anatomie de l'œil et pathologie de la rétinopathie diabétique .....	5
3.1. L'anatomie de l'œil : .....	5
3.2. Parties de l'œil humain :.....	6
3.3. Fonctionnement de l'œil : .....	7
4. Mécanismes de développement de la rétinopathie diabétique .....	7
5. Symptômes et stade de la rétinopathie diabétique .....	8
5.1 La rétinopathie diabétique périphérique non-proliférante.....	8
5.2 La rétinopathie diabétique périphérique proliférante .....	8

5.3. L'œdème maculaire diabétique.....	9
6. Conclusion.....	9
Chapitre 2 : État de l'art.....	10
1. Introduction .....	10
2. Méthodes traditionnelles de détection précoce .....	10
2.1. Examen clinique .....	10
2.2. L'imagerie médicale :.....	11
3. Introduction de l'intelligence artificielle en ophtalmologie.....	12
3.1 Compréhension des réseaux neuronaux convolutifs (CNN).....	13
3.1.1 Pourquoi les ConvNets plutôt que les réseaux neuronaux Feed-Forward ?.....	13
3.1.2 Image input.....	14
3.1.3 Convolution Layer.....	15
3.1.4 Non-linéarité (ReLU) .....	16
3.1.5 Couche Pooling .....	17
3.1.6 Couche Fully Connected FC .....	18
3.2 Compréhension des machines à vecteurs de support (SVM).....	19
3.2.1 Fonctionnement du SVM .....	20
4. Travaux connexes.....	20
4.1. Mode Connecté : .....	21
4.2. Mode hors ligne :.....	25
4.3. Recherches concernant la validation des résultats : .....	27
5. Synthèse .....	28
6. Conclusion.....	29
Chapitre 3 : Méthodologie proposée .....	30
1. Introduction .....	30
2. Méthodologie proposée .....	30
3. Architecture du système .....	32
4. Fonctionnement général du système .....	33
5. Présentation de l'ensemble de données .....	35

5.1 Collecte de données.....	35
5.2 Structure de dataset .....	35
5.3 préparer les générateurs de données.....	36
6. Architecture du modèle .....	38
6.1 Rétinopathie diabétique RD .....	38
6.2 Configuration et paramétrage du modèle RD .....	40
6.2.1 Fonction Loss .....	41
6.2.2 Optimiseurs .....	41
7. Conclusion.....	43
Chapitre 4 : implémentation et résultats expérimentaux .....	45
1. Introduction .....	45
2. Représentation des outils de développement .....	45
2.1 Environnements physique .....	45
2.2 Logiciels et bibliothèques utilisés dans la mise en œuvre.....	46
2.3 Langage de programmation.....	48
3. Dispositif expérimental .....	49
3.1 Préparation et flux de travail des données.....	49
3.2 Mesures d'évaluation .....	49
4. Discussion et comparaison des résultats obtenus .....	50
4.1 Résultats et évaluation du modèle RD .....	51
4.2 Comparaison de nos résultats obtenus avec les différents modèles .....	63
4.3 Comparaison de notre travail avec les travaux existants.....	64
5. Interface système.....	66
5.1. Page d'accueil .....	66
5.2. Les boutons de fonctionnement.....	67
6. Test de système .....	67
6.1. Détection de rétinopathie diabétique.....	67
6.2. Détection de l'absence de rétinopathie diabétique.....	68
7. Conclusion.....	69

Conclusion générale et perspectives .....	71
Références .....	73

# Listes des figures

---

Figure 1 : Anatomie des yeux [5].....	5
Figure 2 Exemple d'architecture CNN [11] .....	13
Figure 3 Aplatissement d'une matrice d'image 3x3 en un vecteur 9x1 [11] .....	14
Figure 4 Image RGB 4x4x3 [11].....	14
Figure 5 La matrice de l'image multiplie la matrice du noyau ou du filtre [12] .....	15
Figure 6 La matrice de l'image multiplie la matrice du noyau ou du filtre [12] .....	15
Figure 7 3 x 3 Matrice output [12] .....	15
Figure 8 Quelques filtres courants [12].....	16
Figure 9 Opération ReLU [12] .....	17
Figure 10 Max Pooling [12] .....	18
Figure 11 Après la couche pooling layer, aplatie en tant que couche FC [12] .....	18
Figure 12 Classification SVM [13] .....	19
Figure 13 Fonctionnement SVM [13] .....	20
Figure 14 Principales catégories de diagnostic de la RD .....	21
Figure 15 Medios system. [17].....	26
Figure 16 flux de travail de la méthode proposée CNN&SVM.....	31
Figure 17 flux de travail avec CNN .....	31
Figure 18 Architecture du système.....	33
Figure 19 Fonctionnement général du système CNN&SVM.....	34
Figure 20 Fonctionnement général du système avec CNN .....	34
Figure 21 des exemples de DR et NO-DR dans dataset.....	35
Figure 22 Structure de dataset.....	36
Figure 23 Architecture model RD (CNN).....	38
Figure 24 Création de model (CNN).....	39
Figure 25 Configuration et paramétrage du modèle RD .....	40
Figure 26 la courbe matrice de confusion .....	52
Figure 27 courbe_roc .....	53
Figure 28 courbe_precision_rappel.....	54
Figure 29 la courbe d'accuracy (exactitude).....	55
Figure 30 la courbe de loss (perte) .....	56
Figure 31 la courbe matrice de confusion SVM (classification binaire).....	56
Figure 32 courbe ROC SVM (classification binaire).....	57
Figure 33 la courbe recall SVM (classification binaire) .....	58

Figure 34 matrice de confusion svm (multi classification) .....	60
Figure 35 courbe roc svm (multi classification).....	61
Figure 36 courbe précision rappel svm (multi classification) .....	62
Figure 37 courbe ROC CNN&SVM .....	62
Figure 38 Courbe de précision rappel CNN&SVM .....	63
Figure 39 Page d'accueil .....	66
Figure 40 les boutons de système.....	67
Figure 41 détection DR .....	68
Figure 42 détection NO DR .....	68

# Listes des tableaux

---

Table 1 Caractéristique d’environnement physique.....	45
Table 2 Évaluation du modèle RD .....	51
Table 3 Évaluation du modèle SVM (classification binaire) .....	56
Table 4 rapport model SVM (multi classification) .....	58
Table 5 Comparaison de nos résultats obtenus .....	63
Table 6 Comparaison model-RD avec d’autres travaux .....	64
Table 7 Comparaison model SVM avec d’autres travail .....	65

# Liste des abréviations

---

- **AI** : Artificial Intelligence
- **ARMD** : Age-Related Macular Degeneration
- **CNN** : Convolutional Neural Network
- **DR** : Diabetic Retinopathy
- **HCS** : Health Care System
- **OAD**: Object-Oriented Analysis and Design
- **OMG** : Object Management Group
- **RSD** : reference standard diagnosis
- **SVM** : Support Vector Machine
- **VA** : Veterans Affairs
- **Df** : data frame

# Introduction générale

---

La rétinopathie diabétique est une complication fréquente et potentiellement grave du diabète, qui affecte les vaisseaux sanguins de la rétine. Une détection précoce et précise de cette maladie est essentielle pour prévenir des complications graves et préserver la vision des patients diabétiques. Au fil des années, le deep learning s'est avéré être une approche prometteuse pour l'analyse d'images médicales, offrant des avancées significatives dans la détection et le diagnostic de diverses affections, y compris la rétinopathie diabétique.

Dans ce travail, nous nous concentrons sur l'utilisation du deep learning, en particulier des réseaux de neurones profonds convolutionnels (CNN), pour améliorer la détection précoce de la rétinopathie diabétique. Les CNN ont la capacité d'apprendre automatiquement des caractéristiques visuelles discriminantes à partir d'images brutes, ce qui en fait une approche prometteuse pour l'analyse des images de la rétine.

Cependant, bien que les CNN aient montré de bons résultats dans la détection de la rétinopathie diabétique, il reste des défis à relever pour améliorer leur précision. Par conséquent, dans cette étude, nous visons à améliorer les résultats des travaux existants en modifiant l'architecture du modèle CNN et en combinant les CNN avec les machines à vecteurs de support (SVM).

L'idée d'hybrider les CNN avec les SVM repose sur l'hypothèse que la combinaison des capacités de classification des SVM avec les capacités d'extraction automatique de caractéristiques des CNN pourrait améliorer la performance de détection. Cependant, il est important de noter que la combinaison de ces deux méthodes peut présenter des défis et des limitations, et les résultats obtenus peuvent varier en fonction de l'architecture du modèle, des caractéristiques extraites et des données utilisées.

Dans cette étude, nous proposons une modification de l'architecture du modèle CNN. Nous exploitons ensuite les caractéristiques extraites par le CNN modifié comme entrée pour les SVM, qui effectuent la classification finale.

Le mémoire réalisé dans le cadre de cette recherche est structuré de manière méthodique afin de fournir une présentation claire et cohérente des travaux réalisés. La structure proposée pour ce mémoire est la suivante :

Hormis l'introduction générale et la conclusion générale, on a le chapitre 1, intitulé "**Fondements théoriques**", fournit les bases nécessaires à la compréhension du domaine biomédical de la rétinopathie diabétique. Il décrit en détail l'anatomie du fond d'œil et met en

évidence les principaux éléments de la rétine. De plus, il présente la rétinopathie diabétique, ses causes, ses symptômes et les différents stades de développement.

Le deuxième chapitre intitulé "**Etat de l'art**", met en lumière les approches existantes pour la détection précoce de cette pathologie, en mettant en évidence les technologies utilisées, notamment le deep learning, les CNN (Convolutional Neural Networks) et les SVM (Support Vector Machines).

Le chapitre 3, intitulé "**Méthodologie proposée**", détaille la méthodologie mise en place dans cette recherche. Il présente les données utilisées, ainsi que les techniques de prétraitement appliquées. Ensuite, il décrit en profondeur l'architecture du modèle CNN amélioré qui est proposé pour la détection précoce de la rétinopathie diabétique. Les choix des couches et des paramètres sont exposés. De plus, ce chapitre met en évidence la combinaison du CNN et du SVM pour obtenir de meilleures performances.

Le chapitre 4, intitulé "**Implémentation et résultats expérimentaux**", se concentre sur l'implémentation pratique de l'approche proposée et présente les résultats obtenus lors des expérimentations. Il décrit l'environnement de travail et les outils de programmation utilisés, ainsi que la méthodologie d'évaluation et les métriques utilisées pour mesurer les performances du modèle. Les expérimentations sont détaillées et les résultats sont analysés en profondeur. La partie **discussion**, offre une synthèse des résultats et des accomplissements de la recherche. Elle met en évidence les limitations de l'étude et propose des pistes d'amélioration pour de futures recherches.

# Chapitre 1 : Fondements théoriques

---

## 1. Introduction

---

Ce premier chapitre jette les bases théoriques nécessaires à la compréhension de la rétinopathie diabétique, une complication oculaire majeure du diabète. Nous commençons par explorer les différents types de diabète, tels que le diabète de type 1, le diabète de type 2 et le diabète gestationnel, ainsi que les facteurs de risque associés. Ensuite, nous examinons en détail l'anatomie de l'œil et le rôle crucial de la rétine dans la vision. Nous décrivons les mécanismes de développement de la rétinopathie diabétique, ses symptômes et ses stades. En comprenant ces fondements théoriques, nous serons en mesure de mieux appréhender l'importance de la détection précoce et des interventions appropriées pour cette pathologie.

## 2. Le diabète et complications oculaires

---

### 2.1. Définition du diabète

Le diabète est une maladie chronique caractérisée par des niveaux élevés de glucose dans le sang (glycémie). Il survient lorsque le corps ne produit pas suffisamment d'insuline ou ne parvient pas à utiliser efficacement l'insuline qu'il produit. L'insuline est une hormone produite par le pancréas qui régule le métabolisme des glucides et permet au glucose d'entrer dans les cellules pour fournir de l'énergie.

### 2.2. Type du diabète :

Les trois principaux types de diabète sont le diabète de type 1, le diabète de type 2 et le diabète gestationnel. Les personnes peuvent développer le diabète à n'importe quel âge. Les femmes et les hommes peuvent tous deux développer le diabète.

✚ **Le diabète de type 1 :** Le diabète de type 1, autrefois appelé diabète juvénile, se développe le plus souvent chez les jeunes ; cependant, le diabète de type 1 peut également se développer chez les adultes. Dans le cas du diabète de type 1, l'organisme ne produit plus d'insuline ou suffisamment d'insuline parce que le système immunitaire de l'organisme, qui nous protège normalement des infections en nous débarrassant des bactéries, des virus et d'autres substances nocives, a attaqué et détruit les cellules qui fabriquent l'insuline.

✚ **Diabète de type 2 :** Le diabète de type 2, anciennement appelé diabète de l'adulte, peut toucher des personnes de tout âge, même des enfants. Cependant, il se développe le plus souvent chez les personnes d'âge moyen et plus âgées. Les personnes en surpoids et inactives sont également plus susceptibles de développer un diabète de type 2. Il commence généralement par une résistance à l'insuline - un état qui se produit lorsque les cellules

graisseuses, musculaires et hépatiques n'utilisent pas l'insuline pour transporter le glucose dans les cellules de l'organisme afin de l'utiliser comme énergie. Par conséquent, l'organisme a besoin de plus d'insuline pour aider le glucose à pénétrer dans les cellules. Au début, le pancréas répond à la demande supplémentaire en produisant plus d'insuline. Avec le temps, le pancréas ne produit plus assez d'insuline lorsque la glycémie augmente, par exemple après les repas. Si le pancréas ne peut plus fabriquer suffisamment d'insuline, il faudra traiter votre diabète de type 2.

✚ **Diabète gestationnel** : Le diabète gestationnel peut se développer lorsqu'une femme est enceinte. Les femmes enceintes produisent des hormones qui peuvent entraîner une résistance à l'insuline. Toutes les femmes présentent une résistance à l'insuline à la fin de leur grossesse. Si le pancréas ne produit pas assez d'insuline pendant la grossesse, la femme développe un diabète gestationnel. Les femmes en surpoids ou obèses ont un risque plus élevé de diabète gestationnel. De même, une prise de poids trop importante pendant la grossesse peut augmenter la probabilité de développer un diabète gestationnel. Le diabète gestationnel disparaît le plus souvent après la naissance du bébé. Cependant, une femme qui a souffert de diabète gestationnel est plus susceptible de développer un diabète de type 2 plus tard dans sa vie. Les bébés nés de mères ayant souffert de diabète gestationnel sont également plus susceptibles de souffrir d'obésité et de diabète de type 2.

### **2.3. Complications oculaires liées au diabète :**

Le diabète peut avoir un impact significatif sur les structures de l'œil, entraînant une altération de la vision et, dans certains cas, la perte de la vision. Nous abordons en détail les principales complications oculaires liées au diabète, notamment la cataracte, le glaucome et la rétinopathie diabétique. [1]

#### **2.3.1. La cataracte**

La cataracte est une condition caractérisée par l'opacification partielle ou totale du cristallin, ce qui entraîne une altération de la vision et une détérioration de la qualité de vie. Bien qu'elle puisse se développer dans un seul œil, elle affecte généralement les deux yeux. Lorsque la gêne visuelle ne peut plus être corrigée efficacement par des lunettes, on parle de cataracte.

Si elle n'est pas traitée chirurgicalement, la cataracte progresse et entraîne une diminution graduelle et irréversible de la vision. [2]

#### **2.3.2. Le glaucome**

Le terme "glaucome" fait référence à plusieurs maladies oculaires graves qui, en l'absence de traitement approprié, entraînent une perte de vision irréversible pouvant conduire à la cécité.

Ces maladies sont généralement caractérisées par une augmentation anormale de la pression des liquides à l'intérieur de l'œil. Cette élévation de la pression a pour conséquence la détérioration des fibres responsables de la transmission des informations visuelles de la rétine vers le cerveau. [3]

### 2.3.3. La rétinopathie diabétique

La rétinopathie diabétique (RD) peut résulter de facteurs génétiques et environnementaux et se caractérise par un excès permanent de sucre dans le sang. Face à une augmentation incroyable du nombre de patients, les experts parlent aujourd'hui d'épidémie. Le diabète s'attaque aux vaisseaux sanguins et en particulier à ceux de la rétine, qui est très vascularisée. La rétinopathie diabétique reste aujourd'hui la première cause de cécité chez les jeunes et les malvoyants. Ceci est dû au fait qu'elle est souvent traitée trop tard. En effet, la RD est une affection silencieuse pendant de nombreuses années. Seul un dépistage effectué régulièrement, selon les recommandations de bonnes pratiques cliniques, peut permettre un diagnostic et un traitement précoce [4].

## 3. Anatomie de l'œil et pathologie de la rétinopathie diabétique

### 3.1. L'anatomie de l'œil :

L'œil, l'un des organes sensoriels primordiaux du corps humain, joue un rôle essentiel dans notre capacité à percevoir le monde qui nous entoure. En raison de sa sensibilité et de son exposition constante, il est sujet à diverses affections et maladies. Par conséquent, il est crucial de prendre des mesures de protection et de prévention afin de maintenir sa santé et son bon fonctionnement.




Figure 1 : Anatomie des yeux [5]

Le globe oculaire est composé de trois couches distinctes, chacune remplissant un rôle essentiel dans la fonction visuelle.

- ✚ **La couche sclérotique** : c'est la couche externe, est la partie blanche et opaque de l'œil. Elle constitue la structure protectrice et résistante qui maintient la forme de l'œil.
- ✚ **La choroïde** : Just en dessous de la sclérotique se trouve la deuxième couche, appelée la choroïde. La choroïde est une couche vasculaire qui fournit de l'oxygène et des nutriments aux tissus de l'œil, en particulier à la rétine.
- ✚ **La rétine** : La couche interne est la rétine, qui tapisse le fond de l'œil. C'est là que se trouvent les cellules sensibles à la lumière appelées les photorécepteurs, qui captent les stimuli lumineux et les transforment en signaux électriques transmis au cerveau par le nerf optique, permettant ainsi la perception visuelle.

### 3.2. Parties de l'œil humain :

Les parties de l'œil comprennent :

- ✚ **Iris**, la zone colorée de votre œil. Selon la couleur de vos yeux, l'iris peut être n'importe quelle nuance de bleu, vert, noisette ou brun.
- ✚ **La cornée**, une couche transparente qui s'étend sur l'iris. L'eau et le collagène composent la cornée. Vos larmes protègent votre cornée et la gardent lubrifiée.
- ✚ **Pupille**, le cercle noir qui est une ouverture ou une fenêtre au milieu de votre iris. Il se dilate et se contracte pour contrôler la quantité de lumière qui pénètre dans votre œil.
- ✚ **La sclérotique**, les parties blanches de votre œil qui entourent l'iris.
- ✚ **Conjonctive**, un tissu clair et mince qui recouvre la sclérotique et l'intérieur de vos paupières.
- ✚ **Lens**, qui se trouve derrière la pupille. Il concentre la lumière qui entre dans votre œil et envoie de la lumière à l'arrière de votre œil.
- ✚ **La rétine**, une collection de cellules qui tapissent l'intérieur de l'arrière de l'œil. Faisant partie de votre système nerveux, les rétines détectent la lumière et la convertissent en impulsions électriques ou en signaux neuronaux. La rétine a des bâtonnets (cellules qui vous aident à voir en basse lumière) et des cônes (cellules qui détectent la couleur).
- ✚ **Macula**, une petite zone qui fait partie de la rétine. Il est responsable de la vision centrale et vous aide à voir les détails fins et les couleurs.
- ✚ **Nerf optique**, qui est derrière la rétine. Il transporte des signaux de la rétine à votre cerveau qui interprète ensuite ces informations visuelles pour vous dire ce que vous voyez.
- ✚ **Les muscles**, qui contrôlent la position et le mouvement de vos yeux, la quantité de lumière qui pénètre dans votre œil et la capacité de vos yeux à se concentrer.
- ✚ **Vitreous**, un gel transparent qui remplit tout votre œil. Il protège et maintient la forme de l'œil.

### 3.3. Fonctionnement de l'œil :

Les différentes parties de notre œil travaillent ensemble pour nous aider à voir des images et à envoyer des informations visuelles au cerveau. Ce processus se déroule extrêmement rapidement. Lorsque nous regardons un objet :

- ✚ La lumière pénètre dans l'œil par la cornée et se dirige vers le cristallin. La pupille s'agrandit et se rétrécit pour contrôler la quantité de lumière qui entre dans l'œil.
- ✚ La cornée et le cristallin réfractent (courbent) la lumière pour mettre au point ce que nous voyons.
- ✚ Le nerf optique transmet ces signaux à la partie du cerveau responsable de la vision (cortex visuel). Le nerf optique transporte les signaux des deux yeux à la fois.
- ✚ Le cerveau interprète ce que nous avons vu. Il combine les informations visuelles des deux yeux et les rassemble en une seule image claire.
- ✚ Il existe des centaines d'affections, de troubles, de maladies et de blessures qui affectent les yeux. [6].

## 4. Mécanismes de développement de la rétinopathie diabétique

---

Comme on a déjà cité auparavant, la rétinopathie diabétique est une complication oculaire qui se développe chez les personnes atteintes de diabète. Elle est principalement causée par des fluctuations prolongées et excessives de la glycémie, qui endommagent les vaisseaux sanguins de la rétine. Les mécanismes précis qui conduisent au développement de la rétinopathie diabétique ne sont pas entièrement compris, mais plusieurs facteurs ont été identifiés.

Tout d'abord, l'hyperglycémie chronique entraîne des lésions des parois des vaisseaux sanguins de la rétine, ce qui provoque une fuite de fluides et de protéines. Cette fuite provoque un gonflement de la rétine, appelé œdème maculaire, qui altère la vision. En outre, l'hyperglycémie chronique entraîne également une augmentation de la formation de nouveaux vaisseaux sanguins anormaux dans la rétine, processus appelé néovascularisation. Ces nouveaux vaisseaux sanguins sont fragiles et peuvent saigner, entraînant une perte de vision plus sévère.

De plus, l'inflammation joue un rôle important dans le développement de la rétinopathie diabétique. L'hyperglycémie chronique déclenche une réponse inflammatoire dans les tissus oculaires, ce qui contribue à la progression de la maladie. Les cellules immunitaires libèrent des substances inflammatoires qui endommagent les vaisseaux sanguins et augmentent la perméabilité vasculaire.

## 5. Symptômes et stade de la rétinopathie diabétique

---

Au début de la rétinopathie diabétique, il peut ne pas y avoir de symptômes apparents, et la maladie peut passer inaperçue pendant longtemps. Cependant, à mesure que la maladie progresse, les symptômes peuvent inclure une vision floue, des taches sombres ou vides dans le champ de vision, des difficultés à percevoir les couleurs, une vision nocturne altérée et une vision déformée. Il est important de noter que les symptômes peuvent varier d'une personne à l'autre et que certains patients peuvent ne présenter aucun symptôme jusqu'à ce que la maladie soit avancée.

La rétinopathie diabétique peut être classée en plusieurs stades en fonction de la gravité de la maladie :

### 5.1 La rétinopathie diabétique périphérique non-proliférante

Cette forme est la plus commune. A ce stade, la maladie n'affecte pas encore la vision. Les capillaires rétiniens se fragilisent, se déforment et se dilatent localement, ce qui provoque des écoulements de fluides (sang, eau) et des saignements. Ces vaisseaux peuvent aussi se boucher et provoquer des « infarctus » de la rétine qui vont être à l'origine de la rétinopathie proliférante.

### 5.2 La rétinopathie diabétique périphérique proliférante

La rétinopathie diabétique proliférante périphérique est une forme avancée de la maladie qui affecte environ 15 à 20% des personnes diabétiques. Elle se manifeste lorsque la rétine ne reçoit plus suffisamment d'oxygène en raison de l'obstruction des capillaires, entraînant ce qu'on appelle une ischémie.

Dans cette condition, de nouveaux vaisseaux sanguins anormaux et fragiles, appelés néovaisseaux, se forment dans la rétine et le corps vitré de l'œil. Ces vaisseaux peuvent saigner, ce qui entraîne une perte de vision, car la lumière ne peut plus atteindre les cellules nerveuses de la rétine.

Dans certains cas, le sang peut être résorbé naturellement, ce qui peut améliorer la vision. Cependant, dans de nombreux cas, une intervention chirurgicale est nécessaire pour traiter cette condition. En l'absence de traitement, la perte de vision peut être permanente.

Outre la perte de vision, la rétinopathie diabétique proliférante périphérique peut entraîner d'autres complications. Le décollement de la rétine est une urgence ophtalmologique qui se produit lorsque la rétine se détache de la paroi de l'œil. Le glaucome néo-vasculaire, également une urgence ophtalmologique, se caractérise par une augmentation de la pression à l'intérieur de l'œil en raison de la formation de nouveaux vaisseaux sanguins anormaux.

Il est crucial de consulter un ophtalmologiste régulièrement pour dépister et surveiller la rétinopathie diabétique, en particulier dans sa forme proliférante périphérique, afin de prévenir les complications graves et de préserver la vision.

### **5.3. L'œdème maculaire diabétique**

Il se produit lorsque de l'eau s'accumule dans la rétine en raison de dommages aux capillaires rétiens. Cette accumulation de liquide entraîne un épaissement (gonflement) de la rétine, ce qui affecte la vision dans la zone touchée. Si la macula est endommagée, la vision centrale est fortement réduite. Il est important de noter que les dommages à la macula peuvent se produire indépendamment des dommages à la rétine périphérique.[7]

## **6. Conclusion**

---

En conclusion de ce premier chapitre, nous avons exploré le cadre biomédical de la rétinopathie diabétique, en mettant l'accent sur l'anatomie de la rétine et les structures vasculaires associées. Nous avons examiné les différentes couches de la rétine et leur rôle dans la perception visuelle, ainsi que les altérations tissulaires causées par le diabète.

Nous avons également discuté des complications oculaires liées au diabète, notamment la cataracte, le glaucome et la rétinopathie diabétique. Ces affections peuvent entraîner une détérioration progressive de la vision et une diminution de la qualité de vie des patients diabétiques.

En comprenant les mécanismes de développement de la rétinopathie diabétique, ainsi que les symptômes et les stades de la maladie, nous sommes en mesure de reconnaître l'importance de la détection précoce pour prévenir les complications visuelles et préserver la santé oculaire des patients diabétiques.

Dans le prochain chapitre, nous aborderons en détail les approches existantes utilisées pour la détection précoce de la rétinopathie diabétique, en mettant l'accent sur l'utilisation de techniques d'intelligence artificielle telles que les réseaux de neurones convolutionnels (CNN) et les machines à vecteurs de support (SVM). Nous explorerons les technologies sous-jacentes, telles que le deep learning, qui permettent d'extraire des caractéristiques pertinentes pour la détection de la rétinopathie diabétique.

## 1. Introduction

---

Ce deuxième chapitre se concentre sur l'état de l'art de la détection précoce de la rétinopathie diabétique. Nous examinons les méthodes traditionnelles telles que l'examen clinique de la rétine et l'imagerie médicale, en mettant en évidence leurs avantages et limites. Ensuite, nous nous intéressons aux approches basées sur l'intelligence artificielle, en particulier l'utilisation des réseaux de neurones convolutionnels (CNN) et des machines à vecteurs de support (SVM) pour la détection de la rétinopathie diabétique. Nous discutons des avantages et des limites de ces approches basées sur l'intelligence artificielle. Ce chapitre offre une vision globale des avancées récentes et des défis dans le domaine de la détection précoce de la rétinopathie diabétique.

## 2. Méthodes traditionnelles de détection précoce

---

### 2.1. Examen clinique

L'examen clinique de la rétine est l'une des méthodes traditionnelles utilisées pour la détection précoce de la rétinopathie diabétique. Cet examen est généralement effectué par un ophtalmologiste, qui examine attentivement la rétine à l'aide d'un instrument appelé ophtalmoscope.

L'ophtalmoscope permet à l'ophtalmologiste d'observer la rétine, les vaisseaux sanguins et d'autres structures oculaires afin de détecter d'éventuelles anomalies. Lors de l'examen, le patient est invité à fixer son regard sur un point pendant que l'ophtalmologiste dirige une lumière intense dans l'œil à travers la pupille dilatée.

Lors de cet examen, l'ophtalmologiste recherche des signes de rétinopathie diabétique tels que des hémorragies, des vaisseaux sanguins anormaux, des exsudats (dépôts de lipides) et des œdèmes (accumulation de liquide). Ces signes peuvent indiquer des lésions et des altérations au niveau de la rétine causées par le diabète.

L'examen clinique de la rétine peut fournir des informations importantes sur la présence et la gravité de la rétinopathie diabétique. Cependant, il présente certaines limites, notamment la subjectivité de l'interprétation de l'ophtalmologiste et la dépendance de l'examen sur les compétences et l'expérience du professionnel de la santé. De plus, cet examen ne permet pas une évaluation quantitative et précise des lésions rétinienne. [8]

## 2.2. L'imagerie médicale :

Est une méthode couramment utilisée dans la détection de lésions rétinienne associées à la rétinopathie diabétique. Différentes techniques d'imagerie sont utilisées pour visualiser et évaluer les structures de l'œil, y compris la rétine. Voici quelques-unes des méthodes d'imagerie médicale les plus utilisées :

✚ **La photographie rétinienne** : Cette technique consiste à prendre des photographies haute résolution de la rétine à l'aide d'une caméra spéciale. Les images obtenues permettent de détecter et de documenter les lésions rétinienne telles que les hémorragies, les exsudats et les vaisseaux sanguins anormaux. Cela permet également de suivre l'évolution des lésions au fil du temps.

✚ **La tomographie par cohérence optique (OCT)** : L'OCT est une technique d'imagerie non invasive qui permet de visualiser les différentes couches de la rétine en utilisant des faisceaux de lumière. Cela permet d'obtenir des images en coupe transversale de la rétine, ce qui facilite la détection et la caractérisation des lésions, notamment les œdèmes maculaires et les modifications de l'épaisseur de la rétine.

✚ **La fluorescéine angiographie** : Cette technique implique l'injection d'un colorant fluorescent dans une veine du bras du patient, qui se propage ensuite dans les vaisseaux sanguins de la rétine. Des photographies sont prises à intervalles réguliers pour visualiser la circulation du colorant dans les vaisseaux rétinienne. Cela permet de détecter les vaisseaux sanguins anormaux et de diagnostiquer la rétinopathie diabétique proliférante.

Ces méthodes d'imagerie médicale fournissent des informations détaillées sur les lésions rétinienne et permettent aux médecins d'évaluer la gravité de la rétinopathie diabétique. Cependant, elles présentent également certaines limitations et défis, notamment :

✚ **Coût et accessibilité** : Certains équipements d'imagerie médicale peuvent être coûteux et ne sont pas toujours disponibles dans tous les établissements de santé. Cela peut limiter l'accès à ces technologies pour certains patients.

✚ **Dépendance à l'opérateur** : L'interprétation des images d'imagerie rétinienne nécessite une expertise et une formation spécifiques. Les résultats peuvent varier en fonction des compétences et de l'expérience de l'opérateur, ce qui peut introduire une certaine subjectivité dans l'évaluation des lésions.

✚ **Limitations de résolution et de sensibilité** : Bien que les techniques d'imagerie médicale soient très utiles, elles peuvent ne pas détecter certaines lésions de petite taille ou des changements subtils dans la rétine. Une sensibilité et une résolution plus élevées sont nécessaires pour une détection précoce plus précise.

✚ **Besoin d'expertise en interprétation** : Les images d'imagerie nécessitent une interprétation par des spécialistes formés, tels que des ophtalmologistes. Cela peut entraîner des délais dans le diagnostic et le traitement. [9]

Cependant, étant donné le grand nombre de personnes touchées dans le monde, il n'y a pas suffisamment de spécialistes dans le monde pour dépister toutes les personnes à risque. Cette pénurie est particulièrement aiguë dans les pays en développement, dont l'Inde, et dans de nombreux pays d'Asie et d'Afrique. De plus, de nombreuses personnes touchées résident dans des zones éloignées, où l'accès aux cliniques et aux centres de dépistage est limité, voire inexistant. Par conséquent, la rétinopathie diabétique représente un défi sanitaire mondial urgent qui nécessite une résolution immédiate. [10]

### 3. Introduction de l'intelligence artificielle en ophtalmologie

---

L'idée d'utiliser des programmes informatiques pour évaluer les images rétiniennes dans la rétinopathie diabétique n'est pas nouvelle. Le premier rapport connu d'une telle initiative a été publié en 1996 par Gardner et ses collègues. Il y a près de 25 ans, les auteurs ont entraîné un réseau neuronal sur 147 images de fond d'œil diabétique et 32 images de fond d'œil normal, en cherchant à lui apprendre à reconnaître des caractéristiques d'image spécifiques telles que les vaisseaux, les hémorragies et les exsudats. En raison de nombreuses contraintes, notamment la capacité de calcul, chaque image a été découpée en petits carrés de 20 ou 30 pixels de large, puis évaluée ultérieurement par un ophtalmologiste pour déterminer s'il y avait des vaisseaux, des exsudats, des hémorragies ou des microanévrismes, ou une rétine normale sans vaisseaux. [8]

Depuis le début des années 2000, de nombreux travaux sur le diagnostic automatique des lésions élémentaires de la RD ont été publiés. En se basant sur l'apprentissage automatique, des algorithmes de détection automatique des microanévrismes rétiniens, des microhémorragies rétiniennes et des exsudats ont été développés.

C'est avec les réseaux de neurones profonds convolutifs (CNN ou ConvNet) que l'IA a pris son envol à partir de 2010. Leur plus grande performance est liée au fait qu'ils sont capables d'extraire seuls les caractéristiques des lésions des images, puis de les classer, sans intervention manuelle. Cela permet, pour la RD, un diagnostic plus global ; ils peuvent diagnostiquer sa présence et graduer sa sévérité.

La section suivante se concentrera spécifiquement sur la présentation de CNN (Convolutional Neural Network) et SVM (Support Vector Machine), car ces méthodes seront utilisées dans notre étude à venir.

### 3.1 Compréhension des réseaux neuronaux convolutifs (CNN)

Les réseaux neuronaux convolutifs (CNN) sont des modèles d'apprentissage profond spécialement conçus pour analyser des données visuelles, telles que des images et des vidéos, dans le domaine de la vision par ordinateur. Ces réseaux ont joué un rôle clé dans la croissance exponentielle de l'intelligence artificielle, en permettant aux machines de percevoir et de comprendre le monde visuel de manière similaire aux humains.

L'un des principaux domaines d'application des CNN est la reconnaissance d'images et de vidéos, où ils surpassent souvent les approches traditionnelles en termes de précision et de fiabilité des résultats. Ces réseaux peuvent également être utilisés pour l'analyse et la classification d'images, la création de médias, la recommandation de contenu et le traitement du langage naturel. Leur utilité s'étend à de nombreux secteurs tels que la médecine, l'industrie, les transports, la sécurité, et bien d'autres.

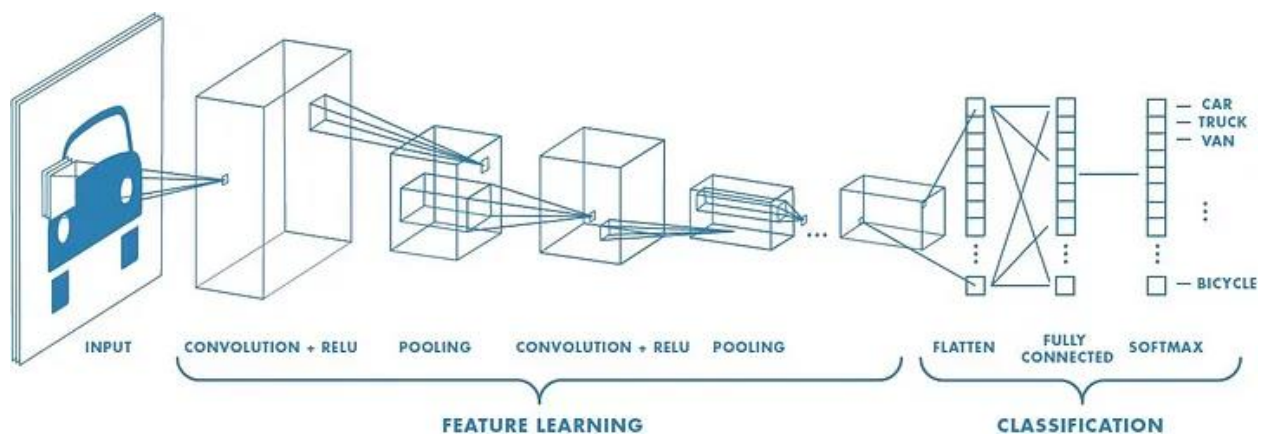


Figure 2 Exemple d'architecture CNN [11]

#### 3.1.1 Pourquoi les ConvNets plutôt que les réseaux neuronaux Feed-Forward ?

Les réseaux neuronaux Feed-Forward, bien que capables de traiter des données tabulaires, peuvent être limités lorsqu'il s'agit de traiter des images complexes. Lorsqu'une image est représentée sous la forme d'un tableau de valeurs de pixels, réduire simplement l'image en un vecteur et l'utiliser dans un perceptron multi-niveau pour la classification pourrait ne pas être suffisant. Cette approche peut fonctionner pour des images binaires simples, mais elle peut ne pas être adaptée pour des images plus complexes où des dépendances entre les pixels sont présentes.

C'est ici que les ConvNets (réseaux de neurones convolutionnels) entrent en jeu. Les ConvNets sont spécifiquement conçus pour le traitement des images et sont capables de capturer efficacement les relations spatiales et temporelles à l'intérieur de l'image en utilisant des filtres appropriés. Leur architecture est particulièrement adaptée pour les ensembles de données d'images, car elle permet de réduire le nombre de paramètres impliqués et offre la possibilité de réutiliser les poids appris à partir de caractéristiques extraites précédemment.

En utilisant des couches convolutionnelles, de pooling et de mise en commun, les ConvNets peuvent extraire des caractéristiques significatives des images, permettant ainsi une meilleure compréhension des motifs et des structures présents. Cette capacité à capturer les dépendances inter-pixels permet aux ConvNets d'obtenir des performances de classification supérieures par rapport aux méthodes traditionnelles basées sur des vecteurs d'images brutes. [11]




Figure 3 Aplatissement d'une matrice d'image 3x3 en un vecteur 9x1 [11]

### 3.1.2 Image input




Figure 4 Image RGB 4x4x3 [11]

La figure ci-dessus illustre une image RVB qui a été divisée en trois plans de couleur : rouge, vert et bleu. Les images peuvent exister dans différents espaces colorimétriques tels que les niveaux de gris, RVB, HSV, CMYK, etc. Le rôle du ConvNet est de transformer les images dans un format plus facile à gérer pour le traitement, tout en conservant les caractéristiques cruciales nécessaires à des prédictions précises. Cet aspect devient crucial lors de la conception d'une architecture qui non seulement facilite les capacités d'apprentissage, mais aussi s'adapte efficacement aux grands ensembles de données. [11]

### 3.1.3 Convolution Layer

La convolution est une étape fondamentale pour extraire les caractéristiques d'une image en entrée. Elle préserve les relations entre les pixels en apprenant les propriétés de l'image à partir de petits carrés de données d'entrée. La convolution est une opération mathématique qui combine un de l'image. Cela permet de mettre en évidence des motifs, des textures ou des structures importantes présentes dans l'image.

- An image matrix (volume) of dimension **(h x w x d)**
- A filter **(f<sub>h</sub> x f<sub>w</sub> x d)**
- Outputs a volume dimension **(h - f<sub>h</sub> + 1) x (w - f<sub>w</sub> + 1) x 1**




Figure 5 La matrice de l'image multiplie la matrice du noyau ou du filtre [12]

Supposons que nous ayons une matrice de filtrage de 5x5 avec des valeurs de pixels d'image de 0 et 1, et une matrice de filtrage de 3x3 comme illustré ci-dessous.




Figure 6 La matrice de l'image multiplie la matrice du noyau ou du filtre [12]

L'opération de convolution consiste à multiplier la matrice d'image 5x5 avec la matrice de filtre 3x3, ce qui aboutit à la création d'une "carte de caractéristiques", comme illustré ci-dessous.




Figure 7 3 x 3 Matrice output [12]

L'application de la convolution à une image avec différents filtres permet d'effectuer des opérations telles que la détection des contours, le flou et l'accentuation. L'exemple ci-dessous montre l'image après avoir subi plusieurs convolutions avec différents types de filtres (noyaux).








Operation	Filter	Convolved Image
<b>Identity</b>	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
<b>Edge detection</b>	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	
<b>Sharpen</b>	$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	
<b>Box blur</b> (normalized)	$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	
<b>Gaussian blur</b> (approximation)	$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$	

Figure 8 Quelques filtres courants [12]

### 3.1.4 Non-linéarité (ReLU)

ReLU (Rectified Linear Unit) est une fonction d'activation non linéaire couramment utilisée dans les réseaux neuronaux convolutifs (ConvNet). Elle est définie comme  $f(x) = \max(0, x)$ , où  $x$  représente l'entrée de la fonction.

L'intérêt de la ReLU réside dans sa capacité à introduire la non-linéarité dans le ConvNet. En appliquant la ReLU, les valeurs linéaires négatives des données sont transformées en zéro, tandis que les valeurs positives restent inchangées. Cette transformation non linéaire est essentielle pour capturer les relations et les modèles complexes dans les données, ce qui permet au ConvNet d'apprendre et de faire des prédictions plus précises. [12]

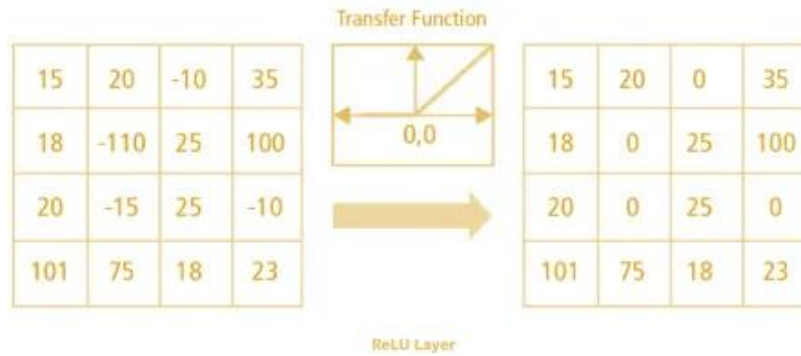


Figure 9 Opération ReLU [12]

D'autres fonctions d'activation non linéaires, telles que Tanh ou Sigmoides, peuvent également être utilisées dans les réseaux neuronaux convolutifs (ConvNet). Cependant, la ReLU est couramment préférée par de nombreux scientifiques des données en raison de ses performances supérieures à celles des deux autres.

ReLU présente plusieurs avantages qui contribuent à sa popularité. Tout d'abord, la ReLU évite le problème de la disparition du gradient rencontré par la Sigmoides et le Tanh, qui peut entraver le processus d'apprentissage des réseaux neuronaux profonds. Le gradient de ReLU reste constant pour les valeurs positives, ce qui permet une rétropropagation efficace. En outre, ReLU est efficace sur le plan du calcul, car la fonction se contente de faire correspondre les valeurs négatives à zéro, ce qui ne nécessite qu'un minimum de ressources informatiques.

Ces caractéristiques de ReLU en font un choix favorable pour l'activation des neurones dans les ConvNets, ce qui permet un apprentissage efficace et une amélioration des performances du modèle. [12]

### 3.1.5 Couche Pooling

Les couches de mise en commun sont utilisées pour réduire le nombre de paramètres dans les réseaux neuronaux convolutifs (ConvNet), en particulier lorsqu'il s'agit d'images de grande taille. Ces couches, également appelées pooling spatial, sous-échantillonnage ou sous-échantillonnage, sont chargées de réduire la dimensionnalité de chaque carte de caractéristiques tout en préservant les informations essentielles.

Le regroupement spatial peut être effectué à l'aide de différentes méthodes, notamment

Mise en commun maximale : Cette approche sélectionne la valeur maximale de la carte rectifiée, capturant ainsi l'élément le plus significatif.

Mise en commun moyenne : Au lieu de sélectionner la valeur maximale, la mise en commun moyenne calcule la moyenne de tous les éléments de la carte.

Mise en commun de la somme : Comme son nom l'indique, la mise en commun de la somme calcule la somme de tous les éléments de la carte.

En appliquant ces techniques de pooling, ConvNet peut condenser les cartes de caractéristiques, ce qui permet une représentation plus compacte des données tout en conservant les détails essentiels nécessaires à des tâches de classification ou d'analyse précises. [12]




Figure 10 Max Pooling [12]

### 3.1.6 Couche Fully Connected FC

La couche FC des réseaux neuronaux convolutifs aplatit les cartes de caractéristiques en un vecteur et relie chaque neurone à chaque neurone de la couche, ce qui permet une extraction complète des caractéristiques et des prédictions précises.




Figure 11 Après la couche pooling layer, aplatie en tant que couche FC [12]

Dans le diagramme donné, la matrice de la carte des caractéristiques est transformée en une représentation vectorielle, qui est ensuite combinée à travers des couches entièrement connectées pour créer une représentation complète. Une fonction de déclenchement telle que Softmax ou Sigmoid est appliquée pour classer les entrées dans des catégories telles que chat, chien, voiture, camion, etc. [12]

## 3.2 Compréhension des machines à vecteurs de support (SVM)

L'algorithme des machines à vecteurs de support (SVM) est un puissant algorithme d'apprentissage supervisé largement utilisé dans différents domaines, tels que la classification, la régression et la détection d'anomalies. Son efficacité repose sur sa capacité à trouver la meilleure séparation linéaire ou non linéaire entre les différentes classes d'un ensemble de données.

L'idée principale derrière les SVM est de trouver un hyperplan dans un espace de dimension supérieure qui sépare de manière optimale les exemples positifs des exemples négatifs. Cet hyperplan est choisi de manière à maximiser la marge, c'est-à-dire la distance entre les exemples les plus proches de chaque classe. Ainsi, les SVM cherchent à trouver la solution qui maximise la marge tout en minimisant l'erreur de classification.

L'algorithme SVM peut également être étendu pour gérer des données non linéairement séparables en utilisant des noyaux. Les noyaux permettent de projeter les données dans un espace de dimension supérieure où elles peuvent être linéairement séparables. Les noyaux les plus couramment utilisés sont le noyau linéaire, le noyau polynomial et le noyau gaussien (ou RBF).




Figure 12 Classification SVM [13]

- ✚ **Vecteurs de support** : sont les points de données les plus proches de l'hyperplan de séparation. Ils sont essentiels pour définir précisément la ligne de séparation en calculant les marges. Ces points jouent un rôle crucial dans la construction du classificateur en fournissant des informations clés sur la distribution des classes.
- ✚ **Hyperplan** : est un plan de décision qui permet de séparer efficacement un ensemble d'objets appartenant à différentes classes. C'est une frontière qui permet de distinguer les exemples positifs des exemples négatifs. L'objectif de l'algorithme SVM est de trouver l'hyperplan qui maximise la marge entre les classes, ce qui contribue à une meilleure séparation et à une généralisation plus précise.

✚ **Marge** : est l'écart entre les deux lignes formées par les vecteurs de support ou les points les plus proches de chaque classe. Elle est calculée comme la distance perpendiculaire entre l'hyperplan et les points de support. Une marge plus grande indique une meilleure séparation entre les classes, tandis qu'une marge plus petite peut indiquer une incertitude ou une possible confusion entre les classes. Ainsi, une marge plus grande est généralement considérée comme bénéfique pour la performance du modèle SVM. [13]

### 3.2.1 Fonctionnement du SVM

L'objectif principal est d'obtenir la meilleure séparation possible d'un ensemble de données donné. La distance entre les points les plus proches est appelée marge. L'objectif est de choisir un hyperplan avec la marge le plus large possible parmi les vecteurs de support d'un ensemble de données donné. Le SVM trouve l'hyperplan de limite maximale au cours des étapes suivantes :

Générer des hyperplans qui séparent les classes de la meilleure façon. Figure de gauche montrant trois hyperplans : noir, bleu et orange. Ici, le bleu et l'orange ont des erreurs de classification plus importantes, mais le noir sépare correctement les deux classes.

Sélectionnez l'hyperplan de droite avec la ségrégation maximale à partir des deux points de données les plus proches, comme le montre la figure de droite. [13]




Figure 13 Fonctionnement SVM [13]

Dans ce qui suit, nous allons présenter un état des lieux des travaux menés dans le cadre de cette problématique afin d'y voir plus clair.

## 4. Travaux connexes

---

Après avoir analysé plusieurs articles dans ce domaine, nous avons constaté que nous pouvions diviser cette recherche en deux grandes catégories :




Figure 14 Principales catégories de diagnostic de la RD

#### 4.1. Mode Connecté :

Parmi plusieurs projets, nous pouvons citer ceux :

1. Les auteurs du projet [14] ont opté pour l'utilisation de techniques d'apprentissage en profondeur qui a révolutionné la détection automatisée de la rétinopathie diabétique (DR). Les systèmes de détection de la DR basés sur l'apprentissage en profondeur exploitent des réseaux de neurones artificiels pour apprendre à reconnaître les caractéristiques de la DR à partir d'images de fond d'œil.

Les réseaux de neurones artificiels sont des structures de traitement de l'information conçues pour imiter le fonctionnement du cerveau humain. Ils sont composés de couches de neurones interconnectés qui traitent l'information en la faisant passer de couche en couche. Ces réseaux sont entraînés à partir de vastes ensembles de données en ajustant les poids de connexion entre les neurones afin de minimiser l'erreur de prédiction.

Dans le contexte de la détection de la DR, les réseaux de neurones sont entraînés à partir d'images de fond d'œil annotées par des experts en ophtalmologie. Les images sont segmentées en régions et chaque région est analysée pour détecter la présence de caractéristiques spécifiques de la DR, comme des microanévrismes ou des hémorragies. Les résultats obtenus sont ensuite agrégés pour produire une prédiction globale indiquant la présence ou l'absence de DR.

Les réseaux de neurones peuvent être entraînés à partir de zéro ou utilisés en tant que modèles pré-entraînés qui ont déjà été formés sur de grandes quantités de données. Pour la détection de la DR, des modèles pré-entraînés sont disponibles, ayant été entraînés sur des milliers d'images de fond d'œil.

L'utilisation de l'apprentissage en profondeur pour la détection de la DR a considérablement amélioré l'exactitude par rapport aux techniques précédentes qui nécessitaient la conception manuelle d'algorithmes pour détecter des caractéristiques spécifiques de la DR. Les modèles d'apprentissage en profondeur ont également la capacité d'apprendre de nouveaux motifs, ce qui leur permet d'identifier des caractéristiques qui n'ont pas été explicitement incluses dans le processus d'entraînement.

2. Quant aux auteurs de [15] ont entraîné un réseau neuronal convolutif profond à l'aide d'un ensemble de données de 5511 photographies rétinienne. Chaque image avait été préalablement attribuée d'un diagnostic de référence standard (RSD) basé sur le consensus de l'évaluation de l'image par 3 experts et du diagnostic clinique par 1 expert (c'est-à-dire normal, pré-plus maladie ou plus maladie). L'algorithme a été évalué par une validation croisée à 5 plis et testé sur un ensemble indépendant de 100 images. Les images ont été collectées auprès de 8 institutions universitaires participant à l'étude de cohorte "Imaging and Informatics in ROP" (i-ROP). L'algorithme d'apprentissage profond a été testé par rapport à 8 experts en ROP, chacun ayant plus de 10 ans d'expérience clinique et plus de 5 publications évaluées par des pairs sur la ROP. Les données ont été collectées de juillet 2011 à décembre 2016, puis analysées de décembre 2016 à septembre 2017.

Une analyse de la courbe caractéristique de fonctionnement du récepteur a été réalisée pour évaluer les performances de l'algorithme par rapport au RSD. Des coefficients kappa pondérés quadratiques ont été calculés pour la classification ternaire (c'est-à-dire normal, pré-plus disease et plus disease) afin de mesurer l'accord avec le RSD et les 8 experts indépendants.

Parmi les 5511 photographies rétinienne incluses, 4535 (82,3 %) ont été classées comme normales, 805 (14,6 %) comme pré-plus disease et 172 (3,1 %) comme plus disease, sur la base du RSD. Les statistiques moyennes (écart-type) de l'aire sous la courbe de la caractéristique de fonctionnement du récepteur étaient de 0,94 (0,01) pour le diagnostic de la normalité (par rapport au pré-plus disease ou plus disease) et de 0,98 (0,01) pour le diagnostic de la plus disease (par rapport à la normalité ou au pré-plus disease). Pour le diagnostic de la plus disease dans un ensemble de test indépendant de 100 images rétinienne, l'algorithme a obtenu une sensibilité de 93 % avec une spécificité de 94 %. Pour la détection du pré-plus disease ou pire, la sensibilité et la spécificité étaient respectivement de 100 % et de 94 %. Sur le même ensemble de test, l'algorithme a obtenu un coefficient kappa pondéré quadratique de 0,92 par rapport au RSD, surpassant 6 des 8 experts en ROP.

3. Les auteurs de [16] passent en revue les différentes approches algorithmiques qui ont été utilisées pour détecter les caractéristiques de la DR, telles que les microanévrismes et les hémorragies, avant l'avènement des techniques d'apprentissage en profondeur. Ils expliquent ensuite comment l'utilisation de l'apprentissage en profondeur a permis une amélioration significative de l'exactitude de la détection de la DR, en particulier en utilisant des réseaux de neurones convolutifs.

Les auteurs examinent également les considérations économiques et de mise en œuvre de la mise en place de programmes de dépistage automatisé de la DR à grande échelle, en

utilisant l'IA. Ils soulignent que l'adoption de l'IA pour la détection de la DR nécessite de trouver un équilibre entre la sensibilité et la spécificité, l'imagerie modale et la capacité à graduer les images, et cela doit être pris en compte dans l'analyse coût-bénéfice.

L'utilisation de l'apprentissage en profondeur a permis une amélioration significative de la détection automatisée de la DR. Cependant, la mise en place de programmes de dépistage automatisé à grande échelle nécessite une analyse économique et une prise en compte des facteurs locaux. Les auteurs soulignent également que la mise en place de programmes de dépistage automatisé de la DR à l'aide de l'IA peut contribuer à améliorer les soins de santé pour les patients atteints de diabète, en permettant une détection précoce de la DR.

4. Les auteurs [17] expliquent comment la rétinopathie diabétique est actuellement classée en fonction de la gravité de la maladie, en utilisant une échelle de cinq étapes appelée l'échelle d'American Academy of Ophthalmology (AAO). Cette classification est généralement effectuée manuellement par des ophtalmologistes, ce qui peut entraîner des erreurs de classification.

Les auteurs de l'article ont utilisé une base de données de plus de 35 000 images de rétines pour développer un modèle d'apprentissage en profondeur capable de classer automatiquement les images en fonction du stade de la rétinopathie diabétique. Le modèle utilise une architecture de réseau de neurones convolutionnels (CNN) pour extraire des caractéristiques à partir des images et une couche de classification pour déterminer le stade de la maladie. Les auteurs ont comparé les performances de leur modèle avec celles d'ophtalmologistes experts, en utilisant un ensemble de données de test distinct.

Les résultats ont montré que le modèle d'apprentissage en profondeur avait une précision de classification supérieure à celle des ophtalmologistes experts, avec une précision globale de 86,4% par rapport à la précision de 80,2% des ophtalmologistes. Le modèle a également obtenu de meilleurs résultats dans la classification des images à des stades intermédiaires de la maladie, où les erreurs de classification des ophtalmologistes étaient les plus fréquentes.

Les auteurs concluent que leur modèle d'apprentissage en profondeur a le potentiel d'améliorer la précision de la classification de la rétinopathie diabétique et peut être utilisé comme un outil complémentaire pour les ophtalmologistes dans le diagnostic de la maladie. Ils soulignent également l'importance de valider le modèle sur des ensembles de données plus vastes et plus diversifiés pour assurer sa généralisation à une population plus large.

5. Les auteurs de [18], mènent une étude sur un grand ensemble de données comprenant plus de 30 000 images rétinienne provenant de plus de 13 000 patients diabétiques. Les images

ont été annotées par des ophtalmologistes expérimentés pour indiquer la présence ou l'absence de rétinopathie diabétique.

L'algorithme de deep learning a été formé à l'aide de ces images annotées pour détecter automatiquement la présence de rétinopathie diabétique dans les images rétinienne. Les résultats ont montré que l'algorithme était hautement sensible et spécifique pour la détection de la rétinopathie diabétique, avec une précision de 97,5 % et une sensibilité de 94,1 %.

Cette étude montre que l'utilisation de l'IA pour la détection de la rétinopathie diabétique peut être efficace et précise, ce qui peut aider à améliorer le dépistage précoce de la maladie et à prévenir la perte de vision chez les patients atteints de diabète. De plus, l'utilisation de la télémédecine peut aider à rendre le dépistage plus accessible aux patients, en particulier dans les régions éloignées ou mal desservies en personnel médical qualifié.

6. [19], cette étude vise à développer un algorithme de détection de la rétinopathie diabétique (RD) basé sur l'intelligence artificielle (IA) pour les photographies du fond d'œil. Les chercheurs ont utilisé un réseau de neurones convolutionnels profonds pour entraîner l'algorithme à détecter les caractéristiques de la RD, telles que les hémorragies et les exsudats. L'algorithme a été testé sur un ensemble de données cliniques comprenant des images de fond d'œil de patients atteints de RD et de patients sains. Les résultats ont montré que l'algorithme avait une précision élevée pour la détection de la RD, avec une sensibilité de 95,6% et une spécificité de 93,2%. Les chercheurs ont conclu que leur algorithme pourrait être utile pour le dépistage de la RD dans les populations à risque et pour améliorer l'efficacité des programmes de dépistage de la RD. Cependant, des tests supplémentaires sont nécessaires pour valider l'efficacité clinique de l'algorithme dans des situations de soins de santé réelles.

7. Les chercheurs de [20] ont utilisé un ensemble de données de photographies du fond d'œil pour entraîner leur modèle de deep learning. Le modèle a ensuite été testé sur un ensemble de données distinct pour évaluer sa capacité à détecter la rétinopathie diabétique.

Les résultats de l'étude ont montré que le modèle était capable de détecter la rétinopathie diabétique avec une précision élevée. Cette précision est très encourageante pour le développement de systèmes automatisés de dépistage de la rétinopathie diabétique. Une telle technologie pourrait être particulièrement utile dans les zones géographiques où les services de santé sont limités.

Il convient de noter que cette étude ne fournit pas d'informations détaillées sur l'architecture spécifique du modèle de deep learning utilisé. Cependant, il souligne l'importance de l'utilisation de l'intelligence artificielle pour la détection précise et efficace de la rétinopathie diabétique.

## 4.2. Mode hors ligne :

Le développement de systèmes de détection automatisée de la rétinopathie diabétique présente des difficultés, notamment en termes de qualité d'image et de variabilité résultant de l'utilisation de différentes caméras de fond d'œil. Certaines initiatives résolvent ce problème en utilisant des techniques informatiques pour normaliser la qualité des images, tandis que d'autres entraînent leurs algorithmes avec des images provenant de plusieurs caméras de fond d'œil. Le coût et la portabilité des équipements constituent également un défi, en particulier dans les régions pauvres en ressources.

Les sociétés d'imagerie du fond d'œil développent actuellement des solutions de dépistage de la RD par IA pour leurs appareils existants [21].

Comme présenté précédemment, plusieurs études ont déjà exploré l'intérêt de l'intelligence artificielle (IA) dans ce domaine, avec des résultats positifs, mais impliquant la nécessité d'utiliser des appareils de rétinothérapie professionnels, ainsi que des plateformes Internet d'IA.

Pour faciliter le dépistage de la rétinopathie diabétique, les chercheurs ont opté pour une solution en mode hors ligne basée sur l'utilisation de smartphones.

La partie suivante, illustre le projet innovant.

Du potentiel de l'utilisation de la photographie du fond de l'œil par smartphone pour le dépistage à faible coût de la rétinopathie diabétique (RD). Une étude a analysé les images rétiniennes de 296 patients prises à l'aide d'un module complémentaire et d'un logiciel pour smartphone appelé Remidio Fundus sur l'appareil téléphonique, qui ont ensuite été analysées par le logiciel Eyeart. Bien que les algorithmes d'Eyeart n'aient pas été formés à l'utilisation des photographies du fond de l'œil prises avec un smartphone, ils ont atteint une sensibilité de 99,3 % pour la RD référençable et de 99,1 % pour la RD menaçant la vue, avec des spécificités de 68,8 % et 80,4 %, respectivement.

Remidio a depuis développé son propre logiciel interne d'analyse de la RD, Medios AI, et ces résultats ont été reproduits dans une autre étude similaire où les images rétiniennes prises avec la caméra mobile Remidio ont été comparées au diagnostic d'un résident et d'un spécialiste en vitréorétine sur la base des mêmes images. Les images ont été prises par un professionnel de la santé n'ayant aucune expérience de l'utilisation des caméras de fond de l'œil, et le système hors ligne a obtenu des résultats de précision tout aussi élevés.



Figure 15 Medios system. [17]

Une autre étude portant sur 297 patients a mesuré les performances du système par rapport à celles de deux spécialistes en vitréorétine. La sensibilité et la spécificité finales de l'IA dans la détection de la RD pouvant être référée étaient de 98,8 % et la spécificité de 86,7 %. Ces résultats ont été corroborés par une étude portant sur 900 adultes diabétiques en Inde, dans laquelle cinq spécialistes de la rétine ont évalué les images prises avec l'appareil photo mobile Remidio pour détecter toute RD ou RDR. Ces images ont ensuite été comparées au logiciel Medios AI fonctionnant hors ligne sur un iPhone 6, un appareil mobile vieux de 6 ans qui coûte actuellement moins de 200 USD pour un modèle remis à neuf. Medios AI a obtenu de bons résultats avec une paire de sensibilité et de spécificité de 83,3 % et 95,5 % pour toute RD et de 93 % et 92,5 % pour la RD.

Le système de dépistage de la RD Remidio effectue l'analyse entièrement hors ligne, sans besoin d'accès à Internet. Bien que l'accès aux sources d'Internet sans fil se répande dans le monde entier, cela peut être un facteur extrêmement important pour le dépistage dans les communautés éloignées et défavorisées où l'accès à Internet est parfois impossible et très souvent peu fiable.

En outre, le passage mentionne la société Bosch, qui a adopté une approche similaire en améliorant sa caméra de fond d'œil "Bosch Mobile Eye Care" et en développant un algorithme de diagnostic DR interne à mettre en œuvre dans la caméra de fond d'œil elle-même. Les images d'un seul champ prises avec leur caméra, sans mydriase pharmacologique, ont été analysées par un logiciel d'IA basé sur un réseau neuronal convolutif afin de fournir un résultat de type maladie/absence de maladie ou qualité insuffisante. Le système est basé sur le cloud et nécessite un accès à Internet. Sur les 1128 yeux étudiés, 44 (3,9 %) ont été jugés non concluants par l'algorithme, et seuls 4 patients sur 568 avaient des images des deux yeux de qualité insuffisante. L'étude a comparé les performances de l'AI avec le classement basé sur l'imagerie stéréoscopique

à 7 champs, mydriatique et ETDRS réalisée sur le même œil. L'algorithme DR de Bosch a obtenu 'de bons résultats avec des taux de sensibilité, de spécificité, de VPP et de VPN de 91 %, 96 %, 94 % et 95 %, respectivement [22].

### **4.3. Recherches concernant la validation des résultats :**

Avec l'augmentation de la prévalence mondiale de la rétinopathie diabétique (RD), un dépistage automatisé de la RD est nécessaire dans les établissements de soins primaires. Deux algorithmes de dépistage automatisé de la RD basés sur l'intelligence artificielle (IA) ont été approuvés par la Food and Drug Administration (FDA) des États-Unis [23].

Plusieurs autres algorithmes sont à l'étude et en cours d'utilisation clinique dans d'autres pays, mais leurs performances dans le monde réel n'ont pas été évaluées de manière systématique. De nombreuses publications ont étudié les performances de plusieurs algorithmes automatisés de dépistage de la RD basés sur l'IA par rapport à des évaluateurs humains lors de l'analyse de données d'imagerie rétinienne en situation réelle.

Parmi ceux-ci, nous avons mentionné :

1. L'étude présentée en [24] , s'agissait d'une étude multicentrique non interventionnelle de validation des dispositifs évaluant un total de 311 604 images rétinienne provenant de 23 724 vétérans qui se sont présentés pour un dépistage télé-rétinien de la RD au Veterans Affairs (VA) Puget Sound Health Care System (HCS) ou Atlanta VA HCS de 2006 à 2018. Cinq sociétés ont fourni sept algorithmes, dont un approuvé par la FDA, qui ont analysé indépendamment tous les scans, quelle que soit la qualité de l'image. La sensibilité/spécificité de chaque algorithme lors de la classification des images comme DR référençable ou non a été comparée aux grades télé-rétiniens VA originaux et à un ensemble de données arbitraires reclassées. La valeur par rencontre a été estimée. En conséquence, bien que des valeurs prédictives négatives élevées (82,72-93,69 %) aient été observées, les sensibilités variaient considérablement (50,98-85,90 %). La plupart des algorithmes n'ont pas fait mieux que les humains par rapport à l'ensemble de données arbitraires, mais deux ont atteint des sensibilités plus élevées, et un a donné une sensibilité (80,47 %,  $P = 0,441$ ) et une spécificité (81,28 %,  $P = 0,195$ ) comparables. Notamment, l'un d'entre eux avait une sensibilité plus faible (74,42 %) pour la RD proliférative ( $P = 9,77 \times 10^{-4}$ ) que les évaluateurs télé-rétiniens de l'AV. La valeur par rencontre variait entre 15,14 et 18,06 dollars pour les ophtalmologistes et entre 7,74 et 9,24 dollars pour les optométristes.
2. L'étude [25] a été menée de manière prospective dans 155 centres de traitement du diabète en Chine. Une photographie du fond d'œil non mydriatique, centrée sur la macula, a été

collectée pour chaque œil et classée selon une classification DR en cinq étapes basées sur l'apprentissage profond (DL). Les images d'un tiers des participants sélectionnés au hasard ont été utilisées pour la validation de l'algorithme d'apprentissage profond.

Au total, 47 269 patients (âge moyen (écart-type), 54,29 (11,60) ans) ont été recrutés. 15 805 participants sélectionnés au hasard ont été examinés par un groupe de spécialistes pour la validation de l'algorithme de DL. Les algorithmes de classification de la RD avaient une sensibilité de 83,3 % (IC 95 % : 81,9 % à 84,6 %) et une spécificité de 92,5 % (IC 95 % : 92,1 % à 92,9 %) pour détecter la RD référençable. La performance de la classification de la RD en cinq étapes (concordance : 83,0 %) est comparable à la variabilité interobservateurs des spécialistes (concordance : 84,3 %). La prévalence estimée chez les patients diabétiques détectés par l'algorithme DL pour toute RD, pour la RD référençable et pour la RD menaçant la vision était respectivement de 28,8 % (IC 95 % : 28,4 % à 29,3 %), 24,4 % (IC 95 % : 24,0 % à 24,8 %) et 10,8 % (IC 95 % : 10,5 % à 11,1 %). La prévalence était plus élevée chez les femmes, les personnes âgées, les diabétiques de longue date et les personnes ayant un taux d'hémoglobine glyquée plus élevé.

L'objectif de ce travail est d'évaluer les performances des classificateurs Décision Tree (DT), Support Vector Machine (SVM) et Probabilistic Neural Network (PNN) dans la détection de la rétinopathie diabétique.

Les résultats correspondants ont montré que SVM a la meilleure force de classification en atteignant une précision de reconnaissance (RA) de 98,50 %, tandis que PNN et DT ont atteint une RA de 97,60 % et 89,20 % respectivement. En termes de taux de fausses acceptations (FAR) et de taux de faux rejets (FRR), le SVM présente les valeurs les plus faibles, à savoir 7,21 et 8,10, tandis que le DT et le PNN affichent respectivement 11,10 et 9,30 et 13,21 et 10,10 [26].

## 5. Synthèse

---

Dans la partie précédente (Travaux connexes), nous avons mentionné certaines recherches entreprises pour diagnostiquer ou détecter la pathologie, en utilisant différentes approches, dont plusieurs (théoriquement disponibles) permettent un diagnostic automatique de la rétinopathie diabétique (DR) avec d'excellentes performances. Jusqu'à présent, nous constatons que l'approche la plus réussie repose sur l'utilisation d'algorithmes d'apprentissage en profondeur, notamment les réseaux neuronaux convolutifs (CNN).

Cependant, cette approche présente certaines limites. Tout d'abord, la précision actuelle de la DR est encore faible et doit être améliorée autant que possible. Le travail a obtenu la plus grande précision, mais avec une précision globale de 92,76%, il reste encore de la marge pour améliorer

la classification de la DR. De plus, quelques études ont porté sur un petit nombre d'instances dans l'ensemble de données, ce qui n'est pas suffisant pour construire un bon classifieur. De plus, très peu de travaux ont été réalisés concernant la classification de la DR en se concentrant sur les trois classes de DR (NO DR, NPDR, PDR). La plupart des études précédentes se sont concentrées uniquement sur deux des classes (NO DR, DR).

Pour cette raison, la plupart d'entre elles utilisent l'imagerie rétinienne comme technique de classification, qui se base sur les anomalies trouvées sur l'image de fond d'œil, telles que les exsudats, les micro-anévrismes, les hémorragies et les vaisseaux sanguins. Bien que la technique d'imagerie rétinienne facilite la détection précoce de la DR, elle nécessite un équipement supplémentaire, qui est souvent coûteux ou parfois indisponible, notamment dans les zones rurales.

D'autre part, plusieurs classifieurs de la DR, en particulier en utilisant le classifieur de Machine à Vecteurs de Support (SVM), ont été développés en utilisant des variables cliniques comme alternative à l'imagerie rétinienne afin de pallier les limitations de la littérature existante et d'améliorer leurs résultats. Cependant, il reste encore une marge de progression, notamment en ce qui concerne la précision des classifieurs.

Ainsi, nous proposons un nouveau cadre basé sur une stratégie d'hybridation, en fusionnant les algorithmes les plus utilisés, à savoir les CNN et les SVM, pour atteindre les taux de précision les plus élevés parmi tous les autres algorithmes de classification couramment utilisés dans ce domaine.

## 6. Conclusion

---

Dans ce deuxième chapitre, on a mené une étude de la détection précoce de la rétinopathie diabétique en explorant les méthodes traditionnelles et les approches basées sur l'intelligence artificielle. Les méthodes traditionnelles comprennent l'examen clinique de la rétine et l'imagerie médicale, mais elles présentent des limitations et des défis en termes de subjectivité et de dépendance à l'expertise humaine.

L'introduction de l'intelligence artificielle en ophtalmologie a mis en évidence l'utilisation des réseaux de neurones convolutionnels (CNN) pour la détection de la rétinopathie diabétique. Ces CNN sont capables d'extraire des caractéristiques pertinentes à partir d'images rétiniennes et de classifier les lésions. Les machines à vecteurs de support (SVM) ont également été mentionnées comme une autre approche pour la classification des images rétiniennes.

# Chapitre 3 : Méthodologie proposée

---

## 1. Introduction

---

Comme nous l'avons vu dans le chapitre précédent, il existe de nombreuses méthodes de diagnostic précoce de la rétinopathie diabétique. C'est pourquoi des systèmes de détection automatique ont été introduits afin de faciliter le processus d'identification et de le rendre disponible à l'échelle mondiale en temps voulu et de manière rentable. Toutefois, en raison du nombre limité d'ensembles de données fiables et de dossiers médicaux concernant cette maladie oculaire particulière, les prédictions obtenues n'étaient pas assez précises pour que les ophtalmologistes puissent s'y fier en tant que systèmes de diagnostic.

Nous proposons donc une combinaison des méthodes CNN et SVM afin de réduire les problèmes et d'augmenter la qualité des résultats.

## 2. Méthodologie proposée

---

Dans cette étude, nous développerons un modèle de classification utilisant des techniques d'apprentissage combinées (CNN et SVM) afin d'obtenir un classificateur optimal avec une précision et une exactitude plus élevée que les modèles existants.

Dans ce modèle, nous présentons une solution pour les systèmes automatisés de détection de la RD, en démontrant les résultats de l'utilisation de plusieurs algorithmes de classification. Comme le montre la figure ci-dessous, des caractéristiques spécifiques ont été introduites dans le cadre de l'ensemble. Pendant ce temps, le modèle sera entraîné en utilisant une partie des ensembles de données choisis. Plusieurs algorithmes de classification largement répandus seront utilisés pour améliorer la précision des prédictions du système, à savoir le réseau neuronal convolutif (CNN), qui effectue des calculs mathématiques complexes pour améliorer la précision, et l'algorithme de la machine à vecteur de support (SVM), qui génère des prédictions de manière précise, rapide et efficace sur le plan du stockage. Au stade final, les résultats de tous les algorithmes seront fusionnés par un méta-classificateur pour produire la prédiction finale.

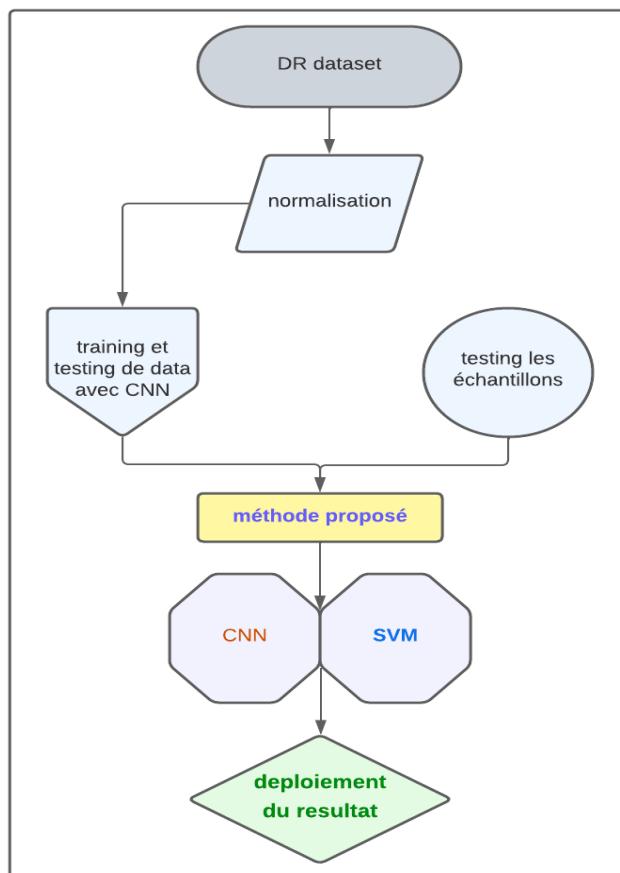


Figure 16 flux de travail de la méthode proposée CNN&SVM

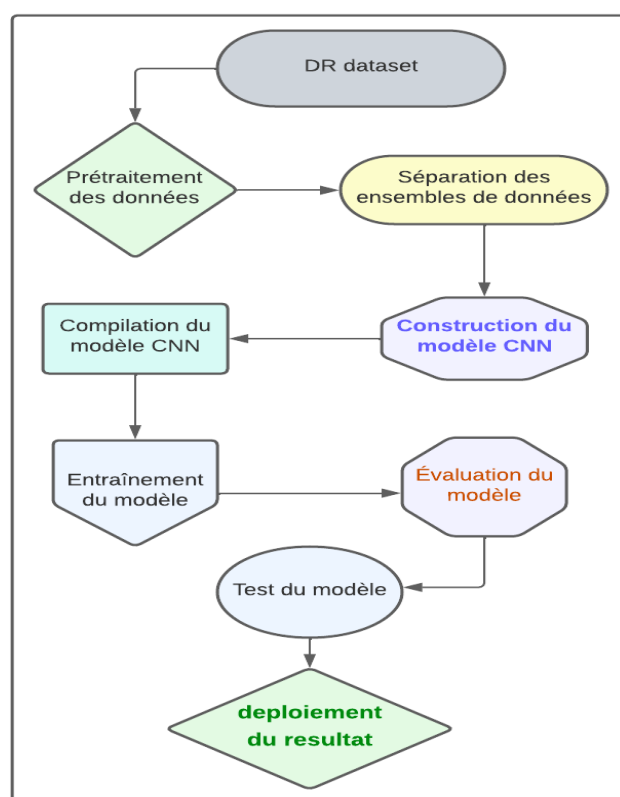


Figure 17 flux de travail avec CNN

### 3. Architecture du système

---

Une méthode hybride utilisant un modèle de classification combinant les réseaux de neurones convolutifs (CNN) et les machines à vecteurs de support (SVM) peut être mise en place. Cette méthode implique le développement d'un modèle de classification à partir d'un ensemble de données soigneusement sélectionné, contenant des images de la rétine avec et sans signes de rétinopathie diabétique.

Le modèle de classification est entraîné en utilisant les caractéristiques extraites à partir des images de la rétine grâce aux couches de convolution et de pooling des réseaux de neurones convolutifs. Les caractéristiques ainsi extraites sont ensuite utilisées pour entraîner le modèle SVM.

Le modèle de classification hybride est ensuite évalué en utilisant plusieurs algorithmes de classification pour sélectionner celui qui fournit les résultats les plus précis et les plus fiables.

Une fois le modèle entraîné et testé avec succès, il peut être déployé dans un système de dépistage de la rétinopathie diabétique. Le modèle de classification hybride est alors utilisé pour classer les images de la rétine en présence ou non de signes de rétinopathie diabétique.

En cas de détection de rétinopathie diabétique, le système de dépistage peut alerter les professionnels de la santé, qui peuvent ensuite prendre les mesures nécessaires pour prévenir et traiter la maladie. Cette méthode hybride de détection de la rétinopathie diabétique est donc un outil pour améliorer le dépistage précoce et la prise en charge de cette maladie.

Dans cette section, nous présentons l'architecture du système proposé, y compris les différents composants impliqués dans son fonctionnement :

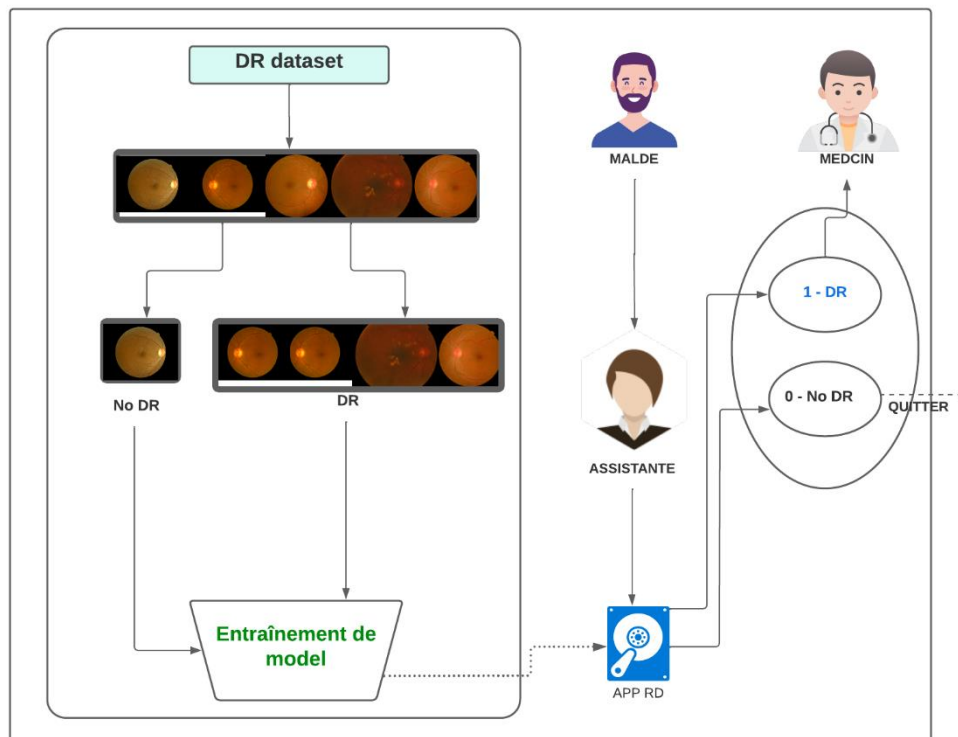


Figure 18 Architecture du système

L'architecture du système se divise en deux parties distinctes. À gauche, nous avons notre système principal qui comprend la lecture des données et l'entraînement du modèle. Une fois cette étape terminée, nous passons à l'application pratique du système.

L'application elle-même est gérée par l'assistante. Elle est intégrée avec l'appareil de photographie du fond d'œil, permettant ainsi de capturer les images nécessaires à l'analyse. Lorsqu'un patient se présente pour une consultation, il interagit avec l'assistante.

En fonction des résultats obtenus, deux scénarios peuvent se produire. Si le patient est diagnostiqué comme étant atteint de la rétinopathie diabétique (DR), il est immédiatement dirigé vers le médecin pour un suivi plus approfondi. En revanche, si le patient est diagnostiqué comme étant non atteint de la rétinopathie diabétique (NO\_DR), il peut quitter la clinique sans nécessiter de consultation médicale supplémentaire.

## 4. Fonctionnement général du système

Le système de détection de rétinopathie diabétique utilise une approche hybride combinant des réseaux de neurones convolutifs (CNN) et des machines à vecteurs de support (SVM) basées sur le deep learning. Le fonctionnement général du système décrit par la figure suivante consiste en plusieurs étapes.

- ✚ Tout d'abord, un ensemble de données contenant des images du fond d'œil de patients atteints de rétinopathie diabétique est préparé. Les images sont annotées par des experts médicaux selon une échelle de gravité de la rétinopathie diabétique clinique (ICDRSS).
- ✚ Ensuite, les images sont utilisées pour entraîner un modèle CNN. Le CNN apprend à extraire automatiquement des caractéristiques pertinentes des images du fond d'œil qui sont discriminantes pour la détection de la rétinopathie diabétique. Pendant l'entraînement, le modèle est optimisé pour minimiser l'erreur de classification entre les différentes catégories de rétinopathie diabétique.
- ✚ Une fois que le modèle CNN est entraîné, les caractéristiques extraites à partir de la couche cachée du CNN sont utilisées comme entrée pour un modèle SVM. Le SVM utilise ces caractéristiques pour effectuer une classification finale des images en différentes catégories de rétinopathie diabétique. Cette étape permet de tirer parti des capacités de généralisation du CNN combinées à la capacité du SVM à effectuer une classification précise.
- ✚ Une fois le modèle hybride CNN-SVM entraîné, il est prêt à être utilisé pour la détection de la rétinopathie diabétique. Les nouvelles images du fond d'œil sont prétraitées pour les adapter à la taille et au format requis par le modèle. Ensuite, les caractéristiques de ces images sont extraites à partir de la couche cachée du CNN et fournies en entrée au SVM pour effectuer la classification.

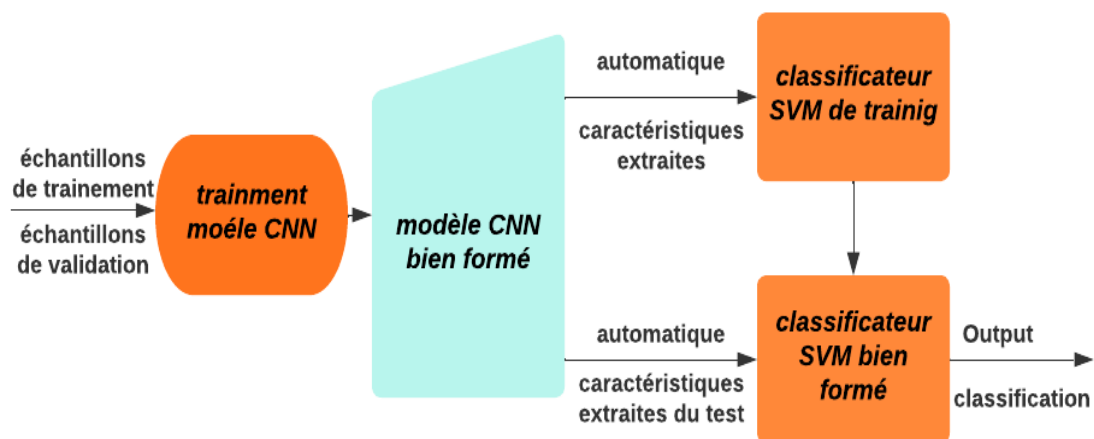


Figure 19 Fonctionnement général du système CNN&SVM

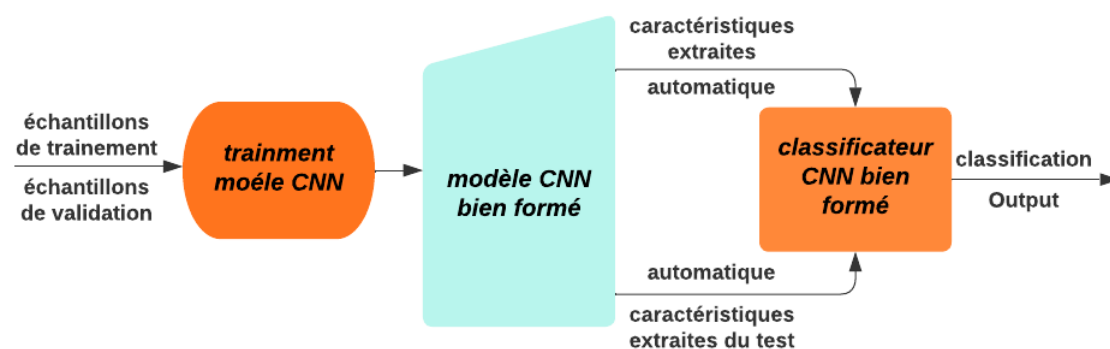


Figure 20 Fonctionnement général du système avec CNN

## 5. Présentation de l'ensemble de données

---

Le passage ensuite expose la présentation de l'ensemble de données utilisé pour créer le modèle du système proposé :

### 5.1 Collecte de données

L'ensemble de données de classification est présenté, provenant du dataset **Diabetic Retinopathy 224x224 Gaussian Filtered**, qui est divisé en groupes de formation, de validation et de test. Cet ensemble de données contient 3662 échantillons de photographies du fond d'œil collectées auprès de participants dans des régions rurales d'Inde, sur une longue période et dans des conditions environnementales variées. L'ensemble de données a été organisé par l'hôpital Aravind Eye en Inde, et les échantillons ont été examinés et étiquetés par des médecins qualifiés selon l'échelle internationale de gravité de la rétinopathie diabétique clinique (ICDRSS). Les échantillons sont classés en cinq catégories selon le niveau de gravité de la rétinopathie diabétique : pas de RD, RD légère, RD modérée, RD sévère et RD proliférative. [27]




Figure 21 des exemples de DR et NO-DR dans dataset

### 5.2 Structure de dataset

Le dataset de rétinopathie diabétique est une base de données souvent utilisée pour la détection de cette pathologie. Elle comprend 5 classes de gravité de la maladie, allant de l'absence de rétinopathie diabétique (classe 0) à la rétinopathie proliférative (classe 4). Le dataset est divisé en 70% pour la phase d'apprentissage et 15% de validation et 15% pour la phase de test. Les données ont été collectées auprès de patients diabétiques, où des photographies de la rétine ont été prises et ensuite étiquetées par des ophtalmologistes pour classer les différentes gravités de la rétinopathie diabétique.

Cet ensemble de données est très utile pour entraîner des modèles de détection automatique de la rétinopathie diabétique basés sur des algorithmes de machine learning, tels que les réseaux de neurones convolutifs (CNN) ou les machines à vecteurs de support (SVM).

Voici ensuite la structure de notre dataset :

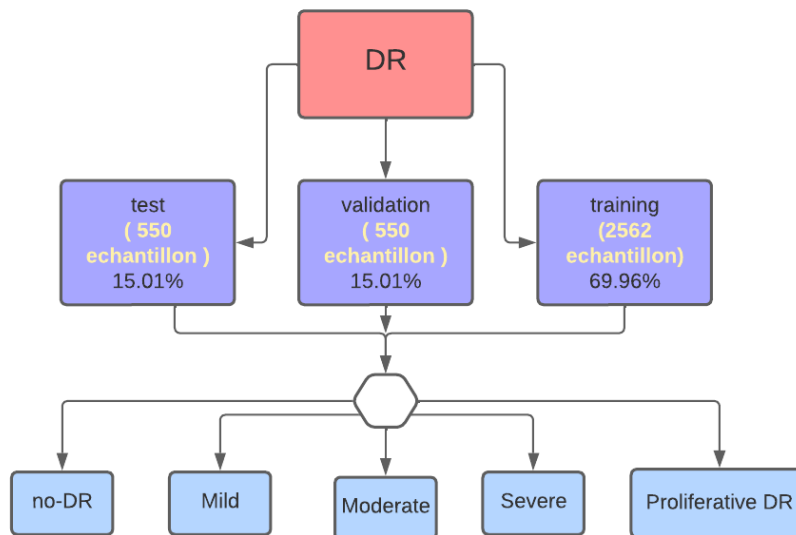


Figure 22 Structure de dataset

La structure des dossiers hiérarchiques ainsi que leurs ratios respectifs sont représentées dans la figure Au-dessus.

### 5.3 préparer les générateurs de données

On se contente de préparer les générateurs de données d'entraînement, de validation et de test en spécifiant le chemin des dossiers contenant les images, la taille cible des images et les options de mélange des données.

- ✚ On à ajouter deux colonnes supplémentaires à un DataFrame. La colonne 'binary\_type' est créée en utilisant une fonction de mappage pour associer les valeurs de la colonne 'diagnosis' à des catégories binaires. Selon le dictionnaire de diagnostic binaire fourni, les valeurs 0, 1, 2, 3 et 4 de la colonne 'diagnosis' sont respectivement associées aux catégories 'No\_DR', 'DR', 'DR', 'DR' et 'DR' dans la colonne 'binary\_type'.
- ✚ La colonne 'type' est créée en utilisant un autre dictionnaire de diagnostic. Les mêmes valeurs de la colonne 'diagnosis' sont associées aux catégories 'No\_DR', 'Mild', 'Moderate', 'Severe' et 'Proliferate\_DR' dans la colonne 'type'.
- ✚ Une fois que les nouvelles colonnes sont ajoutées, le DataFrame est affiché avec les cinq premières lignes à l'aide de la méthode head().
- ✚ On a utilisé la classe ImageDataGenerator de la bibliothèque Keras pour préparer les générateurs de données d'entraînement, de validation et de test.
- ✚ ImageDataGenerator est configuré avec le paramètre rescale = 1/255 pour normaliser les valeurs des pixels des images entre 0 et 1.
- ✚ Le générateur de données d'entraînement est créé à l'aide de la méthode flow\_from\_directory de ImageDataGenerator. Il spécifie le chemin du dossier contenant

les données d'entraînement (`train_path`), la taille cible des images (`target_size = (224,224)`), et l'option `shuffle=True` pour mélanger les données lors de l'entraînement.

- ✚ De même, les générateurs de données de validation et de test sont créés avec les chemins respectifs (`val_path` et `test_path`), la taille cible des images, et l'option `shuffle=True` pour mélanger les données lors de la validation et `shuffle=False` pour maintenir l'ordre des données lors du test.

## 6. Architecture du modèle

### 6.1 Rétinopathie diabétique RD

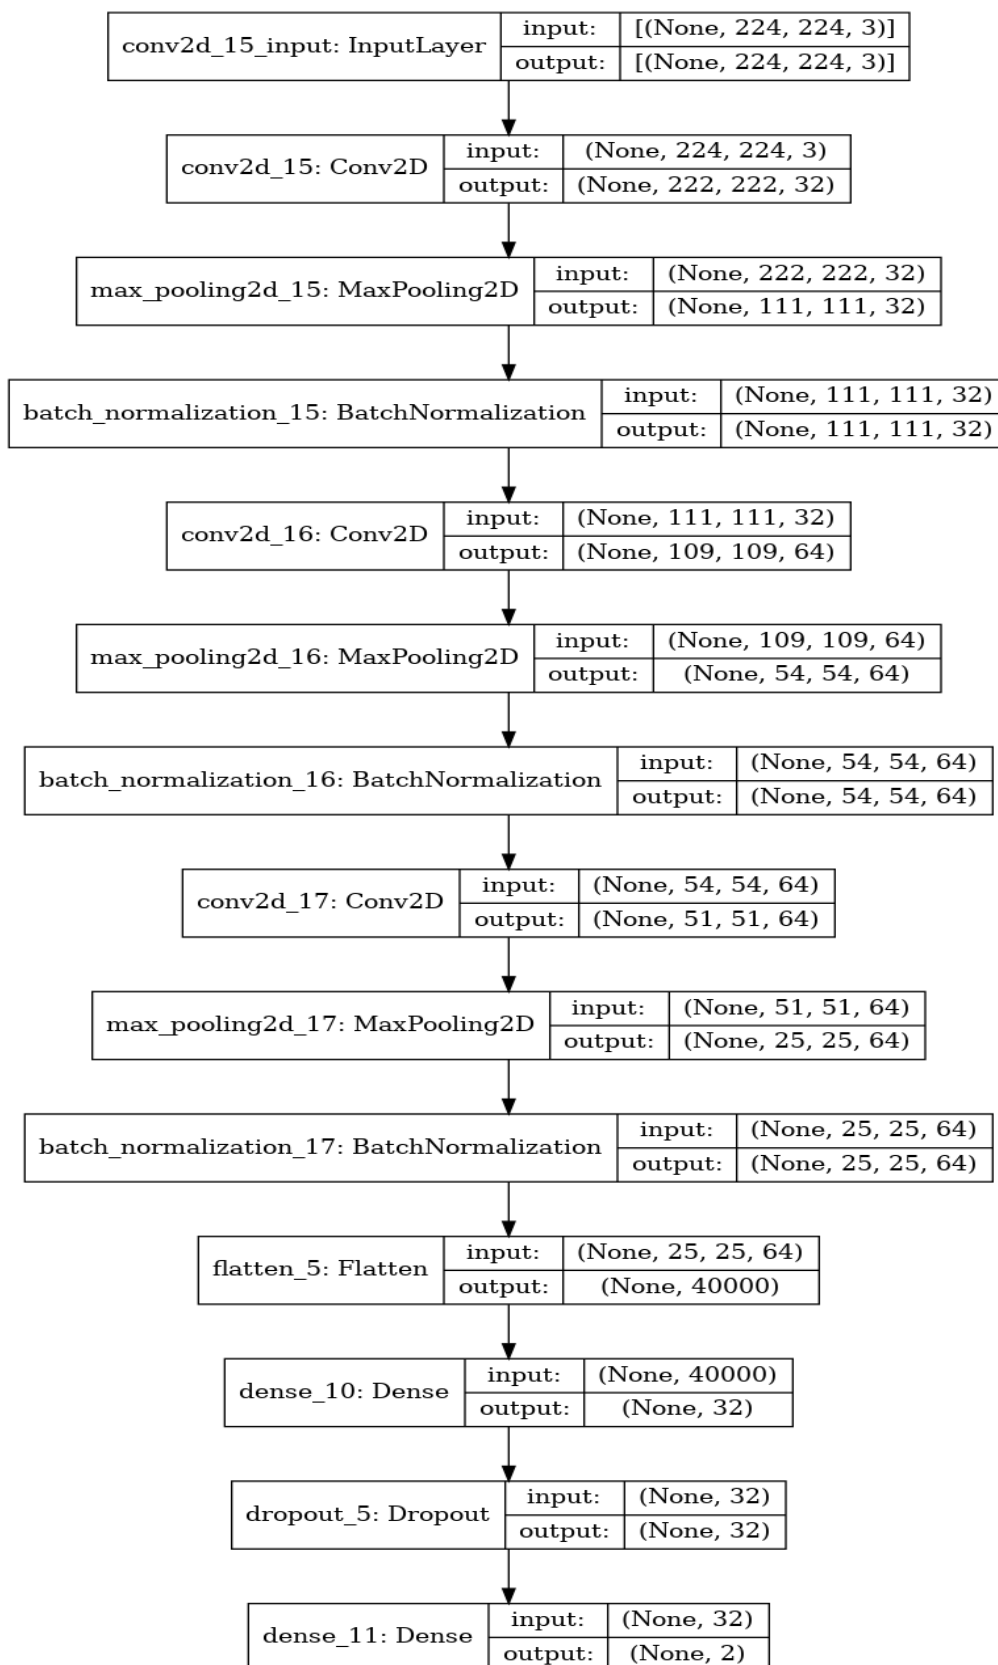


Figure 23 Architecture model RD (CNN)

**Construire le modèle**

```

model = tf.keras.Sequential([
layers.Conv2D(32, (3,3), padding="valid", input_shape=(224,224,3), activation = 'relu'),
layers.MaxPooling2D(pool_size=(2,2)),
layers.BatchNormalization(),
layers.Conv2D(64, (3,3), padding="valid", activation = 'relu'),
layers.MaxPooling2D(pool_size=(2,2)),
layers.BatchNormalization(),
layers.Conv2D(64, (4,4), padding="valid", activation = 'relu'),
layers.MaxPooling2D(pool_size=(2,2))
layers.BatchNormalization(),
layers.Flatten(),
layers.Dense(32, activation = 'relu'),
layers.Dropout(0.15),
layers.Dense(2, activation = 'softmax')
])

```

Figure 24 Création de model (CNN)

La section suivante explique chaque type de couche utilisé dans l'architecture de notre modèle CNN, comme le montre la figure ci-jointe.

- ✚ Couche de convolution (Conv2D) : Cette couche convolue les entrées avec 32 filtres de taille (3,3) et utilise une fonction d'activation ReLU pour introduire la non-linéarité.
- ✚ Couche de max pooling (MaxPooling2D) : Cette couche effectue une opération de pooling en utilisant des fenêtres de taille (2,2) pour réduire la dimensionnalité spatiale des sorties de la couche précédente.
- ✚ Couche de normalisation par lots (BatchNormalization) : Cette couche normalise les activations de la couche précédente, ce qui permet une meilleure stabilité et une convergence plus rapide de l'apprentissage.

Ces trois premières couches se répètent deux fois dans l'architecture avec des paramètres différents pour extraire des caractéristiques de plus en plus abstraites.

- ✚ Couche de mise à plat (Flatten) : Cette couche convertit les sorties en un vecteur unidimensionnel afin de les passer à des couches entièrement connectées.

- ✚ Couche dense (Dense) : Cette couche entièrement connectée contient 32 neurones et utilise la fonction d'activation ReLU.
- ✚ Couche de régularisation (Dropout) : Cette couche désactive aléatoirement certains neurones avec une probabilité de 0,15 pendant l'entraînement, ce qui aide à prévenir le surapprentissage.
- ✚ Couche de sortie (Dense) : Cette couche contient 2 neurones correspondant aux classes de sortie et utilise la fonction d'activation softmax pour obtenir les probabilités des différentes classes.

En résumé, cette architecture utilise des couches de convolution, de pooling, de normalisation par lots, des couches entièrement connectées et des couches de régularisation pour construire un modèle de classification d'images.

## 6.2 Configuration et paramétrage du modèle RD

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d (MaxPooling2D)	(None, 111, 111, 32)	0
batch_normalization (Batch Normalization)	(None, 111, 111, 32)	128
conv2d_1 (Conv2D)	(None, 109, 109, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 64)	0
batch_normalization_1 (Batch Normalization)	(None, 54, 54, 64)	256
conv2d_2 (Conv2D)	(None, 51, 51, 64)	65600
max_pooling2d_2 (MaxPooling2D)	(None, 25, 25, 64)	0
batch_normalization_2 (Batch Normalization)	(None, 25, 25, 64)	256
flatten (Flatten)	(None, 40000)	0
dense (Dense)	(None, 32)	1280032
dropout (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 2)	66

```

Total params: 1,365,730
Trainable params: 1,365,410
Non-trainable params: 320

```

Figure 25 Configuration et paramétrage du modèle RD

**Total params (nombre total de paramètres) :** Ce nombre représente le nombre total de paramètres dans le modèle, qu'ils soient entraînaibles ou non. Ces paramètres incluent les poids des

connexions entre les neurones et les paramètres de normalisation, de mise à l'échelle, etc. Cela peut être considéré comme la capacité totale du modèle à apprendre des données.

**Trainable params (nombre de paramètres entraînaables) :** Ce chiffre représente le nombre de paramètres dans le modèle qui seront ajustés lors de l'entraînement pour apprendre à représenter les données et effectuer des prédictions précises. Il exclut généralement les paramètres qui sont fixés ou qui ne sont pas appris, tels que ceux des couches de pooling ou de normalisation.

**No-trainable params (nombre de paramètres non entraînaables) :** Ce nombre représente le nombre de paramètres dans le modèle qui ne seront pas ajustés lors de l'entraînement. Il comprend généralement les paramètres fixes ou prédéfinis, tels que ceux des couches de pooling ou de normalisation, qui ne nécessitent pas de mises à jour.

### 6.2.1 Fonction Loss

La fonction de perte d'entropie croisée binaire, également connue sous le nom de perte de logarithme binaire, est souvent utilisée dans les tâches de classification binaire. Elle mesure la différence entre la distribution de probabilité prédite et la distribution de probabilité réelle.

La formule de la fonction de perte d'entropie croisée binaire est la suivante :

$$L_{binary-crossentropy} = -\frac{1}{N} \sum_{i=1}^N \times [Y_i \log \log(\hat{y}_i) + (1 - y_i) \log \log(1 - \hat{y}_i) ]$$

Où  $Y_i$  est l'étiquette effective du ième échantillon (0 ou 1),  $(\hat{y}_i)$  est la probabilité prédite que le ième échantillon soit 1 et N est le nombre total d'échantillons.

Le premier terme de l'équation,  $Y_i \log \log(\hat{y}_i)$ , fait que le modèle prédit une faible probabilité pour l'échantillon positif (l'étiquette réelle est 1), tandis que le second terme  $(1 - y_i) \log \log(1 - \hat{y}_i)$  pénalise le modèle lorsqu'il prédit une probabilité élevée d'échantillon négatif (l'étiquette effective est 0). En additionnant les pertes pour tous les échantillons, nous obtenons la perte totale d'entropie croisée binaire pour le modèle.

En d'autres termes, la fonction de perte d'entropie croisée binaire mesure le degré de correspondance entre les probabilités prédites et les étiquettes réelles. Elle est souvent utilisée dans les modèles de régression logistique et les réseaux neuronaux avec une fonction d'activation sigmoïdale dans la dernière couche pour les tâches de classification binaire. L'objectif du processus de formation est de minimiser cette fonction de perte afin d'améliorer les performances du modèle.

### 6.2.2 Optimiseurs

Voici quelques optimiseurs couramment utilisés en apprentissage profond :

- ✚ Stochastic Gradient Descent (SGD) : Il s'agit d'un optimiseur classique qui met à jour les poids du modèle en fonction du gradient de la fonction de perte calculée sur un seul échantillon d'entraînement à la fois ou sur un petit lot (mini-batch) d'échantillons. Il est simple et efficace, mais peut prendre plus de temps pour converger vers une solution optimale.

$$w = w - \text{learning\_rate} \times \text{gradient}$$

L'équation  $w = w - \text{taux\_apprentissage} \times \text{gradient}$  résume l'essence de l'optimisation par descente de gradient, où les poids sont ajustés en fonction du gradient et du taux d'apprentissage. Cela permet au modèle d'apprendre à partir des données et d'améliorer ses performances pour effectuer des prédictions précises.

- ✚ RMSprop : Cet optimiseur utilise également une estimation adaptative des moments du gradient, mais il utilise une moyenne exponentielle des carrés des gradients précédents. Il peut être efficace pour les problèmes non stationnaires.

$$v = \text{beta} * v + (1 - \text{beta}) * \text{gradient}^2$$

$$w = w - \text{learning\_rate} * (\text{gradient} / (\text{sqrt}(v) + \text{epsilon}))$$

Dans cette équation,  $v$  représente une moyenne exponentielle des carrés des gradients précédents,  $\text{beta}$  est un facteur de décroissance qui contrôle l'influence des gradients précédents,  $\text{gradient}$  est le gradient calculé par rétropropagation,  $\text{learning\_rate}$  est le taux d'apprentissage et  $\text{epsilon}$  est une petite valeur ajoutée pour éviter la division par zéro.

La première étape consiste à mettre à jour  $v$  en combinant le gradient au carré pondéré par le facteur  $\text{beta}$  et le carré du gradient actuel. Ensuite, les poids ( $w$ ) sont mis à jour en soustrayant le produit du taux d'apprentissage et du gradient divisé par la racine carrée de  $v$  (ajoutée avec  $\text{epsilon}$  pour éviter une division par zéro).

- ✚ Adaptive Moment Estimation (Adam) : Cet optimiseur combine les avantages du SGD et de l'optimiseur RMSprop. Il utilise une estimation adaptative des moments du gradient pour mettre à jour les poids du modèle. L'optimiseur Adam est souvent utilisé en raison de sa bonne performance dans un large éventail de tâches.

La première équation représente le calcul du premier moment du gradient :

$$m = \text{beta}_1 \times m + (1 - \text{beta}_1) \times \text{gradient}$$

La deuxième équation calcule le deuxième moment du gradient :

$$v = \text{beta}_2 \times v + (1 - \text{beta}_2) \times \text{gradient}^2$$

Enfin, la troisième équation met à jour les poids du modèle en utilisant les estimations du premier et du deuxième moment du gradient :

$$w = \frac{w - \text{learning\_rate} \times m}{\sqrt{v} + \text{epsilon}}$$

L'optimiseur Adam est une méthode d'optimisation couramment utilisée dans l'apprentissage automatique. Il met à jour les poids du modèle en utilisant les estimations du premier et du deuxième moment du gradient. Les équations  $m = \beta_1 \times m + (1 - \beta_1) \times \text{gradient}$  et  $v = \beta_2 \times v + (1 - \beta_2) \times \text{gradient}^2$  calculent ces estimations. Ensuite, les poids sont mis à jour selon l'équation  $w = (w - \text{learning\_rate} \times m) / (\sqrt{v} + \text{epsilon})$ , où le taux d'apprentissage (`learning_rate`) contrôle la taille des pas de mise à jour des poids et l'epsilon est une petite valeur ajoutée pour éviter la division par zéro. L'utilisation de l'optimiseur Adam permet une convergence plus rapide et plus stable lors de l'entraînement du modèle.

Dans notre implémentation, nous utiliserons l'optimiseur Adam pour la mise à jour des poids du modèle. Adam est un optimiseur qui combine les avantages du SGD et de l'optimiseur RMSprop. Il utilise une estimation adaptative des moments du gradient pour ajuster les poids du modèle de manière efficace. L'optimiseur Adam est largement utilisé en raison de sa bonne performance dans de nombreux domaines d'application.

## 7. Conclusion

---

Dans ce chapitre, nous avons décrit la conception de notre système de détection de la rétinopathie diabétique en mettant en évidence le processus étape par étape de son développement. Nous avons présenté en détail notre approche hybride combinant un réseau neuronal convolutif (CNN) personnalisé et une machine à vecteurs de support (SVM), optimisée pour détecter les signes de rétinopathie diabétique dès les premières couches tout en conservant une structure légère.

L'utilisation d'une approche hybride nous permet de tirer parti des avantages des CNN en termes de capacité d'apprentissage automatique à partir des données, tout en exploitant les capacités des SVM en termes de classification et de prise de décision. Cette combinaison nous permet de bénéficier de la précision et de la robustesse des CNN, tout en utilisant les SVM pour améliorer la séparation des classes et la capacité de généralisation du modèle.

De plus, nous avons également utilisé une architecture CNN classique pour la détection de la rétinopathie diabétique. Nous avons entraîné le CNN sur un ensemble de données annotées afin qu'il puisse apprendre à détecter les signes de la maladie dans les images de la rétine. Cette approche s'est avérée efficace pour détecter la rétinopathie diabétique, mais nous avons également constaté que les CNN ont des exigences matérielles élevées et que le processus d'entraînement peut être long.

Dans l'ensemble, notre étude met en évidence l'utilisation de méthodes hybrides, combinant CNN et SVM, ainsi que l'utilisation de CNN seuls pour la détection de la rétinopathie diabétique. Ces approches nous ont permis de développer des systèmes robustes et fiables pouvant être

intégrés à un appareil spécifique prenant des photos de la rétine pour détecter la rétinopathie diabétique. Nous sommes convaincus que nos systèmes peuvent apporter une contribution précieuse dans le domaine de la détection précoce de la rétinopathie diabétique, permettant ainsi une prise en charge plus rapide et efficace des patients atteints de cette maladie.

# Chapitre 4 : implémentation et résultats expérimentaux

## 1. Introduction

---

Dans ce dernier chapitre, nous entrons dans la phase de mise en œuvre, qui consiste à traduire les résultats obtenus lors de la phase conceptuelle en un programme ou un logiciel informatique s'exécutant sur une machine à l'aide des outils de développement adaptés au problème que nous traitons. Nous décrirons les composants de l'environnement de travail, ainsi que les outils de mise en œuvre, et nous donnerons quelques exemples des interfaces réalisées dans notre application.

Nous commençons par présenter une liste des outils de développement qui seront utilisés pour créer notre système. Ensuite, nous présentons les résultats de nos expériences menées pour tester l'efficacité de notre méthode proposée. Nous avons examiné la distribution de l'ensemble de données et préparé les fonctions de flux de données utilisées pour l'entraînement et l'évaluation. De manière importante, nous présentons les résultats de nos expériences ainsi qu'une discussion de leurs implications. Enfin, nous introduisons l'interface du système et montrons quelques captures d'écran de la phase de test en temps réel.

## 2. Représentation des outils de développement

---

### 2.1 Environnements physique

Matériel	Spécification
Nom de l'ordinateur	Asus
Mémoire installée (RAM)	4,00 Go DDR3
Mémoire installée (ROM)	HDD 1TB
Type de système	Système d'exploitation 64 bits, processeur x64
Processeur	Intel(R) Core (TM) i5-5200U à 2,20 GHz


Table 1 Caractéristique d'environnement physique.

Au cours de la phase d'entraînement de notre modèle sur Kaggle, nous avons utilisé les ressources disponibles de manière optimale. Nous avons bénéficié d'une session maximale de 12

heures pour exécuter nos scripts d'entraînement. Pour accélérer nos calculs, nous avons utilisé l'accélérateur GPU T4 \* 2, qui nous a fourni une mémoire GPU de 14,2 Go.

En ce qui concerne le stockage, nous avons eu accès à un espace disque de 73,1 Go pour stocker temporairement nos données et résultats intermédiaires pendant le processus d'entraînement.

En résumé, lors de notre phase d'entraînement sur Kaggle, nous avons bénéficié d'une session de 12 heures, utilisé l'accélérateur GPU T4 \* 2 avec 14,2 Go de mémoire GPU, et disposé de 73,1 Go d'espace disque pour le stockage.

 **Kaggle** est une plateforme complète qui offre des compétitions de science des données, des notebooks interactifs, des jeux de données, des kernels, des forums et une communauté active. Elle permet aux utilisateurs d'apprendre, de collaborer, de résoudre des problèmes et de partager leurs connaissances dans le domaine de la science des données et de l'apprentissage automatique.

- ✚ Notebooks : Kaggle fournit un environnement basé sur le cloud pour créer, exécuter et partager des notebooks interactifs. Les notebooks permettent aux utilisateurs d'écrire du code en Python et R, de visualiser les données, d'explorer des modèles et de partager leurs analyses avec la communauté.
- ✚ Accélération GPU : Kaggle propose des ressources de calcul puissantes, y compris des accélérateurs GPU, pour permettre aux utilisateurs de tirer parti de la puissance de calcul pour leurs projets d'apprentissage automatique et de science des données.
- ✚ Kernels : Les kernels sont des scripts interactifs hébergés sur Kaggle qui permettent aux utilisateurs de partager leur code, leurs visualisations et leurs analyses. Ils sont utilisés pour présenter des méthodes, des solutions de compétition ou des projets exploratoires.

En résumé, Kaggle est une plateforme complète qui offre des compétitions de science des données, des notebooks interactifs, des jeux de données, des kernels, des forums et une communauté active. Elle permet aux utilisateurs d'apprendre, de collaborer, de résoudre des problèmes et de partager leurs connaissances dans le domaine de la science des données et de l'apprentissage automatique.

## 2.2 Logiciels et bibliothèques utilisés dans la mise en œuvre

Nous avons effectué une sélection minutieuse des outils en fonction de leur efficacité et de leur adaptabilité à notre projet :



**Visual Studio Code** est un éditeur de code source léger mais puissant, conçu pour fonctionner sur les systèmes d'exploitation Windows, macOS et Linux. Il offre une prise en charge native du JavaScript, du TypeScript et du Node.js, ainsi qu'un écosystème étendu d'extensions pour d'autres langages et environnements d'exécution, tels que le C++, le C#, Java, Python, PHP, Go et .NET. Visual Studio Code est apprécié pour sa polyvalence et sa capacité à s'adapter à divers besoins de développement, offrant aux utilisateurs une expérience de codage agréable et productive. [28]

Voici une brève description de chaque bibliothèque utilisée dans notre code :

- ✚ **tensorflow** : TensorFlow est une bibliothèque open-source d'apprentissage automatique et de calcul numérique. Elle offre un ensemble d'outils et de modules pour la création, l'entraînement et le déploiement de modèles d'apprentissage automatique.
- ✚ **tensorflow.lite**: TensorFlow Lite est une version légère de TensorFlow spécialement conçue pour le déploiement de modèles d'apprentissage automatique sur des appareils mobiles, des systèmes embarqués et d'autres plates-formes à ressources limitées.
- ✚ **keras**: Keras est une bibliothèque open-source d'apprentissage profond qui sert d'interface conviviale pour la création et l'entraînement de modèles d'apprentissage automatique. Elle est intégrée à TensorFlow et offre une syntaxe simplifiée pour la construction de réseaux de neurones.
- ✚ **Numpy**: NumPy est une bibliothèque fondamentale pour le calcul scientifique en Python. Elle fournit des structures de données de tableau multidimensionnel et des fonctions mathématiques pour manipuler ces tableaux de manière efficace.
- ✚ **Pandas** : Pandas est une bibliothèque Python utilisée pour la manipulation et l'analyse des données. Elle offre des structures de données de haute performance, notamment les DataFrames, qui permettent de traiter et de manipuler facilement les données tabulaires.
- ✚ **random** : Le module random de Python fournit des fonctionnalités pour générer des nombres aléatoires et effectuer des opérations de tirage au sort.
- ✚ **Os** : Le module os fournit des fonctions pour interagir avec le système d'exploitation, notamment pour effectuer des opérations de gestion de fichiers et de dossiers.
- ✚ **shutil** : Le module shutil permet d'effectuer des opérations de haut niveau sur les fichiers et les dossiers, notamment la copie, le déplacement et la suppression.
- ✚ **matplotlib.pyplot**: Matplotlib est une bibliothèque de visualisation de données en Python. Le module pyplot fournit des fonctions pour créer des graphiques et des visualisations.

- ✚ **matplotlib.image.imread** : La fonction `imread` de `matplotlib.image` est utilisée pour lire des images à partir de fichiers.
- ✚ **ImageDataGenerator (module de `keras.preprocessing.image`)**: `ImageDataGenerator` est une classe de générateur de données d'image de Keras qui facilite l'augmentation des données et la préparation des lots d'images pour l'entraînement des modèles d'apprentissage automatique.
- ✚ **categorical\_accuracy (module de `tensorflow.keras.metrics`)**: `categorical_accuracy` est une métrique de classification qui calcule la précision catégorielle, c'est-à-dire la proportion d'échantillons correctement classés par rapport au nombre total d'échantillons.
- ✚ **train\_test\_split (module de `sklearn.model_selection`)**: `train_test_split` est une fonction de scikit-learn qui permet de diviser un ensemble de données en sous-ensembles d'entraînement et de test pour l'évaluation du modèle.

Ces bibliothèques sont couramment utilisées dans le domaine de l'apprentissage automatique et sont essentielles pour le développement et l'entraînement de modèles de réseau neuronal.

## 2.3 Langage de programmation

**Python** : Python n'est qu'un parmi de nombreux langages de programmation. Tout comme les langues humaines, il existe plusieurs langages de programmation tels que Java, LISP, PHP, Perl, ainsi que C et d'autres langages utilisés pour des tâches spécifiques telles que les scripts UNIX. Chacun de ces langages a ses forces : Java est apprécié pour sa portabilité, PHP excelle dans la création de pages web dynamiques avec accès aux bases de données, et ainsi de suite. Cependant, la plupart de ces langages partagent des concepts fondamentaux communs tels que la manipulation de données à travers des variables et l'utilisation de fonctions pour effectuer des opérations sur ces données. Python est un langage de programmation puissant et élégant qui intègre ces fonctionnalités communes à de nombreux autres langages.

Il est largement utilisé dans des applications réelles et bénéficie d'une grande communauté de développeurs passionnés. De plus, Python est un logiciel libre et dispose d'une implémentation standardisée, ce qui facilite son utilisation et sa diffusion. Apprendre Python peut également faciliter l'apprentissage d'autres langages de programmation, car de nombreux concepts sont similaires. [29]

## 3. Dispositif expérimental

---

### 3.1 Préparation et flux de travail des données

- ✚ Lire les données : Nous lisons un fichier CSV contenant des informations sur des images médicales liées à un diagnostic spécifique (rétinopathie diabétique). Les données sont stockées dans un DataFrame nommé "df".
- ✚ Création de dictionnaires de diagnostic : Nous allons créer deux dictionnaires, "diagnosis\_dict\_binary" et "diagnosis\_dict", qui associent les codes de diagnostic aux catégories de diagnostic correspondantes.
- ✚ Ajout de nouvelles colonnes : Nous ajoutons deux nouvelles colonnes "binary\_type" et "type" au cadre de données "df". Ces colonnes sont créées à l'aide de dictionnaires de diagnostic afin de faire correspondre les codes de diagnostic aux catégories appropriées.
- ✚ Exploration des données : Les premières lignes de "df" sont affichées ; DataFrame pour vérifier que les nouvelles colonnes ont été ajoutées correctement. Nous utilisons ensuite des diagrammes à barres pour visualiser la distribution des catégories de diagnostic en "types" ; et "binary\_type" ; Columns.
- ✚ Division des données en ensembles de formation, de validation et de test : nous utilisons la fonction `train_test_split` de la bibliothèque `scikit-learn` pour diviser `df` ; DataFrame en trois phrases : "train", "val" et "test". L'ensemble de validation représente 15 % des données, et les ensembles de formation et de test sont ajustés en conséquence pour maintenir une proportion similaire.
- ✚ Création du répertoire de travail : Nous créons les répertoires "train", "val" et "test" pour stocker les images associées à chaque ensemble.
- ✚ Copier les images dans les répertoires de travail : Nous copions les images du répertoire source dans les répertoires appropriés des fichiers de formation, de validation et de test. Les images sont triées en fonction de leur catégorie de diagnostic.
- ✚ Configuration d'ImageDataGenerator : Configurons ImageDataGenerator de Kera pour qu'il normalise les valeurs des pixels des images et les redimensionne à 224x224 pixels. Avec ces configurations, nous créons des générateurs d'images pour les ensembles de formation, de validation et de test.

### 3.2 Mesures d'évaluation

Nous avons implémenté notre projet en utilisant Python et le framework d'apprentissage profond TensorFlow. Nous avons suivi une approche basée sur le réseau de neurones convolutifs (CNN) à l'aide de la bibliothèque Keras. Nous avons divisé notre ensemble de données en ensembles d'entraînement, de validation et de test, et nous avons entraîné notre modèle sur

l'ensemble d'apprentissage. Pour évaluer les performances de notre méthode, nous avons utilisé des mesures d'évaluation telles que la précision (accuracy), la précision par classe et la matrice de confusion. Nous avons analysé les résultats obtenus sur l'ensemble de test pour évaluer l'efficacité de notre modèle dans la détection et la classification des différentes catégories de rétinopathie diabétique avec les mesures d'évaluation suivant :

- ✚ Précision (Accuracy) : C'est le pourcentage de prédictions correctes par rapport au total des prédictions.

$$\text{Accuracy} = (\text{Nombre de prédictions correctes}) / (\text{Nombre total de prédictions})$$

- ✚ Précision par classe : Cette mesure évalue la précision pour chaque classe d'intérêt individuellement, fournissant ainsi des informations détaillées sur la performance de la méthode pour chaque catégorie de rétinopathie diabétique.

$$\text{Précision} = (\text{Nombre de vrais positifs}) / (\text{Nombre de vrais positifs} + \text{Nombre de faux positifs})$$

- ✚ Matrice de confusion : Cet outil permet de visualiser les performances du modèle en comparant les prédictions réelles avec les prédictions faites par le modèle. Il fournit des informations sur les faux positifs, les faux négatifs et les vrais positifs.

- ✚ Courbe ROC (Receiver Operating Characteristic) : Elle représente la performance du modèle en mesurant le taux de vrais positifs par rapport au taux de faux positifs à différents seuils de classification. Elle est souvent utilisée pour évaluer la capacité de discrimination du modèle.

- ✚ Courbe PR (Precision-Recall) : Cette courbe représente la relation entre la précision et le rappel du modèle à différents seuils de classification. Elle est utile lorsque les classes sont déséquilibrées et permet d'évaluer la capacité du modèle à trouver les exemples positifs tout en maintenant une faible proportion de faux positifs.

Ces mesures d'évaluation nous ont permis de quantifier la performance de notre méthode dans la détection et la classification de la rétinopathie diabétique, en fournissant une évaluation globale ainsi que des détails sur la précision par classe.

## 4. Discussion et comparaison des résultats obtenus

---

Dans cette section, nous discuterons et comparerons les résultats obtenus en utilisant différentes architectures de modèles pour la détection et la classification de la rétinopathie diabétique. Nous avons exploré trois approches différentes : l'architecture personnalisée que nous avons développée précédemment, ainsi que l'utilisation d'un réseau de neurones convolutifs CNN seul et SVM en seul et une combinaison de CNN et SVM.

## 4.1 Résultats et évaluation du modèle RD

Le modèle de classification binaire des images médicales utilise une architecture séquentielle avec des couches de convolution, une couche dense et une couche de sortie. Il est entraîné sur 30 époques avec un taux d'apprentissage de  $1e-5$  et l'optimiseur Adam. L'architecture comprend des couches de convolution avec différents filtres, suivies d'une activation Relu, d'un pooling et d'une normalisation par lot. Les caractéristiques extraites sont ensuite aplaties et passées à une couche dense avec activation ReLU. Une couche de désactivation est ajoutée pour réduire le surapprentissage, et la dernière couche utilise une activation softmax pour obtenir les probabilités de chaque classe. Le modèle est compilé avec Adam, la perte binaire "BinaryCrossentropy" et l'exactitude comme métrique. L'entraînement utilise un générateur d'images avec augmentation des données et une répartition de 70% pour l'entraînement, 15% pour la validation et 15% pour les tests. Lors de la prédiction, l'image de test est normalisée, puis le modèle donne la classe prédite (DR ou No DR).

Après l'entraînement du modèle, évaluez ses performances en utilisant des mesures telles que la courbe ROC, la matrice de confusion, la précision, le rappel et le score F1. La courbe ROC trace le taux de vrais positifs par rapport aux faux positifs à différents seuils de classification. La matrice de confusion donne une vue détaillée des prédictions du modèle. Calculez la précision, le rappel et le score F1 pour une évaluation plus précise. Les courbes d'apprentissage visualisent l'évolution des scores d'entraînement et de validation, aidant à détecter le surapprentissage ou le sous-apprentissage.

### 4.1.1 Evaluation et résultats model RD (CNN)

#### Rapport

	DR	No_DR	accuray	Macro-avg	weighted avg
Précession	0.97	0.97		0.97	0.97
rappel	0.97	0.97		0.97	0.97
F1-score	0.97	0.97	0.97	0.97	0.97

Table 2 Évaluation du modèle RD

**Précision (Precision)** : Cela mesure la proportion d'instances correctement prédites comme positives parmi toutes les instances prédites comme positives. Pour la classe 0, la précision est de 0.97, ce qui signifie que 97% des instances prédites comme classe 0 sont réellement de la classe 0. Pour la classe 1, la précision est de 0.97, ce qui signifie que 97% des instances prédites comme classe 1 sont réellement de la classe 1.

**Rappel (Recall)** : Cela mesure la proportion d'instances correctement prédites comme positives parmi toutes les instances réellement positives. Pour la classe 0, le rappel est de 0.97, ce

qui signifie que 97% des instances de la classe 0 ont été correctement prédites. Pour la classe 1, le rappel est de 0.97, ce qui signifie que 97% des instances de la classe 1 ont été correctement prédites.

**F1-score** : C'est une mesure de la précision globale du modèle qui tient compte à la fois de la précision et du rappel. Il est calculé comme une moyenne pondérée de la précision et du rappel. Le score F1 est de 0.97 pour les deux classes, ce qui indique une bonne performance globale du modèle.

**Précision globale (Accuracy)** : Cela mesure la proportion d'instances correctement prédites parmi toutes les instances. L'exactitude globale est de 0.97, ce qui signifie que 97% des instances ont été correctement prédites par le modèle.

#### 🚦 Matrice de confusion

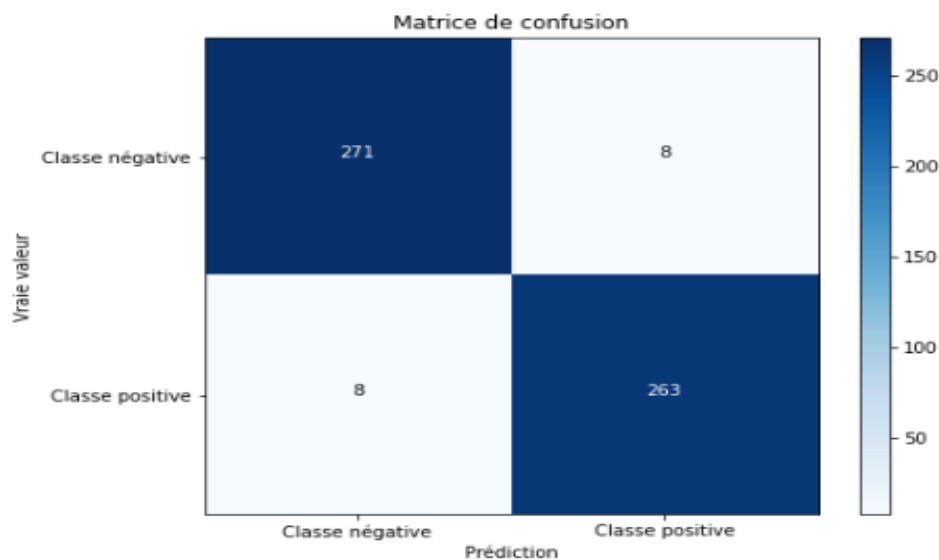


Figure 26 la courbe matrice de confusion

Lors de l'analyse de la matrice de confusion, les termes utilisés sont les suivants :

**Vrai positif (VP)** : le nombre d'échantillons de la classe positive qui ont été correctement prédits comme positifs. Dans notre cas, il y a 263 vrais positifs.

**Faux négatif (FN)** : le nombre d'échantillons de la classe positive qui ont été incorrectement prédits comme négatifs. Dans notre cas, il y a 8 faux négatifs.

**Vrai négatif (VN)** : le nombre d'échantillons de la classe négative qui ont été correctement prédits comme négatifs. Dans notre cas, il y a 272 vrais négatifs.

**Faux positif (FP)** : le nombre d'échantillons de la classe négative qui ont été incorrectement prédits comme positifs. Dans notre cas, il y a 8 faux positifs.

## Courbe ROC

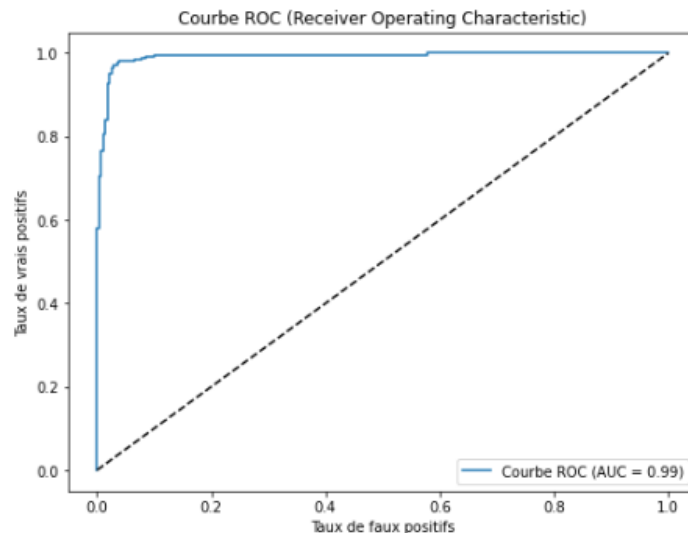


Figure 27 courbe\_roc

- Performance élevée : Une AUC de 0.99 est proche de la valeur maximale de 1, ce qui suggère que notre modèle est capable de faire une distinction précise entre les exemples positifs et négatifs. Il prédit avec une grande précision quelles instances appartiennent à chaque classe.
- Bonne capacité de discrimination : Une AUC de 0.99 indique une très faible probabilité de faux positifs et de faux négatifs. Cela signifie que le modèle est capable de minimiser les erreurs de classification en assignant correctement les exemples aux classes appropriées.
- Forte séparation des classes : Une AUC élevée indique une bonne séparation des distributions des classes. Cela peut être dû à des caractéristiques distinctes et informatives présentes dans les données, qui permettent au modèle de prendre des décisions précises.
- Robustesse du modèle : Une AUC de 0.99 suggère que le modèle est capable de généraliser correctement sur de nouvelles données, car il démontre une performance élevée à la fois sur les données d'entraînement et de test.

Il est important de noter que la courbe ROC seule ne fournit pas d'informations détaillées sur les performances du modèle pour chaque seuil de classification.

## ✚ Courbe de précision rappel

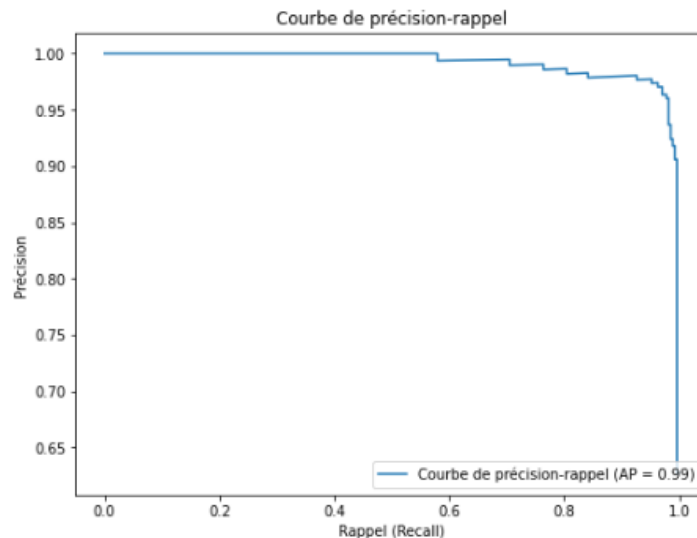


Figure 28 courbe\_precision\_rappel

- Haute précision : Un score AP de 0.99 suggère que notre modèle est capable de fournir des prédictions précises pour les exemples positifs. Cela signifie que la proportion d'exemples positifs prédits correctement est très élevée.
- Rappel élevé : Un score AP élevé indique également que notre modèle est capable de rappeler avec succès une grande proportion d'exemples positifs réels. Il identifie efficacement les cas positifs parmi tous les exemples disponibles.
- Bon équilibre entre précision et rappel : Un score AP élevé suggère que notre modèle maintient un bon équilibre entre la précision et le rappel. Cela signifie qu'il minimise à la fois les faux positifs et les faux négatifs, ce qui est important pour une tâche de classification binaire équilibrée.
- Capacité à classer les exemples : Un score AP de 0.99 indique que le modèle est capable de classer les exemples avec une grande précision, en identifiant correctement les exemples positifs et négatifs. Cela démontre sa capacité à bien généraliser sur de nouvelles données.

Il est important de noter que la courbe de précision-rappel fournit une évaluation plus détaillée de la performance du modèle à différents seuils de classification. En examinant la courbe, vous pouvez choisir le seuil qui correspond le mieux à vos besoins en termes de précision et de rappel, en fonction du problème spécifique qu'on a à résoudre.

## ✚ Accuracy et validation accuracy

Courbe d'Accuracy (Exactitude) :

- `history.history['acc']` représente l'exactitude (accuracy) sur les données d'entraînement à chaque epoch.

- `history.history['val_acc']` représente l'exactitude sur les données de validation à chaque epoch.
- En utilisant la fonction `plt.plot()`, les valeurs de l'exactitude sur les données d'entraînement et de validation sont tracées.
- Le titre du graphique est défini comme "Acc" (abréviation d'Accuracy).
- Les axes des abscisses (x) et des ordonnées (y) sont étiquetés avec "Epochs" et "Accuracy" respectivement.
- La légende du graphique affiche les labels "Train" (entraînement) et "Validation" pour indiquer les courbes correspondantes.
- Enfin, la fonction `plt.show()` est utilisée pour afficher le graphique.




Figure 29 la courbe d'accuracy (exactitude)

#### ✚ Loss et validation\_loss

Courbe de Loss (Perte) :

- `history.history['loss']` représente la perte (loss) sur les données d'entraînement à chaque epoch.
- `history.history['val_loss']` représente la perte sur les données de validation à chaque epoch.
- De manière similaire à la courbe d'accuracy, les valeurs de perte sur les données d'entraînement et de validation sont tracées à l'aide de `plt.plot()`.
- Le titre du graphique est défini comme "Loss" (perte).
- Les axes des abscisses (x) et des ordonnées (y) sont étiquetés avec "Epochs" et "Loss" respectivement.
- La légende du graphique affiche les labels "loss" (perte) et "Val\_loss" (perte de validation).
- La fonction `plt.show()` est utilisée pour afficher le graphique.




Figure 30 la courbe de loss (perte)

#### 4.1.2 Evaluation et résultats model SVM (classification binaire)

##### 📊 Rapport

	DR	No_DR	accuray	Macro-avg	weighted avg
Précession	0.94	0.92		0.93	0.93
rappel	0.93	0.93		0.93	0.93
F1-score	0.93	0.93	0.93	0.93	0.93

Table 3 Évaluation du modèle SVM (classification binaire)

D'après les résultats fournis, le modèle SVM semble avoir des performances très bien avec une précision de 0.92 pour la classe : 0 : 'No\_DR', et 0.94 pour 1 : 'DR'. Cela signifie que le modèle prédit prêt correctement les instances pour les classes.

De plus, le score AUC (Roc) est également de 0.93 pour les deux classes, ce qui indique que le modèle est capable de distinguer très bien entre les classes positives et négatives.

Le F1-score est également de 0.93 pour les deux classes, ce qui indique un équilibre entre la précision et le rappel (recall). Cela signifie que le modèle parvient à identifier correctement les instances positives tout en minimisant les faux positifs et les faux négatifs.

##### 📊 Matrice de confusion




Figure 31 la courbe matrice de confusion SVM (classification binaire)

D'après la matrice de confusion que nous avons :

Cette matrice de confusion spécifique indique que notre modèle a bien classé 344 instances positives et 338 instances négatives. Cependant, il a fait des erreurs en classant 23 instances négatives comme positives et 28 instances positives comme négatives. La matrice de confusion peut être utilisée pour calculer diverses mesures de performance telles que la précision, le rappel et le score F1 pour évaluer plus en détail les performances de notre modèle de classification.

### 🚦 Courbe ROC




Figure 32 courbe ROC SVM (classification binaire)

Dans le cas de notre modèle SVM, l'analyse de la courbe ROC avec une AUC de 0.93 suggère que le modèle a une capacité de discrimination parfaite. Cela signifie qu'il est capable de minimiser à la fois les faux positifs et les faux négatifs, en donnant des scores plus élevés aux instances positives et des scores plus bas aux instances négatives.

### 🚦 Courbe de précision rappel




Figure 33 la courbe recall SVM (classification binaire)

Lorsque la courbe de précision-rappel à une AP de 0.93, cela indique que le modèle SVM est extrêmement précis dans ses prédictions pour les instances positives, tout en capturant également tous les exemples positifs présents dans les données.

#### 4.1.3 Evaluation et résultats model SVM (multi classification)

##### Rapport

	Précession	rappel	F1-score	Support
Mild	0.38	0.36	0.37	69
Moderate	0.61	0.74	0.67	201
NO_DR	0.86	0.97	0.91	367
Proliférate_DR	0.67	0.04	0.08	47
Sever	0.75	0.12	0.21	49
accuray			0.73	733
Macro-avg	0.65	0.45	0.45	733
weighted avg	0.73	0.73	0.69	733

Table 4 rapport model SVM (multi classification)

D'après les résultats fournis, le modèle SVM semble avoir des performances asset bien :

- Classe "Mild" :

La précision est de 0.38, ce qui indique que seulement 38% des prédictions positives pour cette classe sont correctes.

Le rappel est de 0.36, ce qui signifie que seulement 36% des véritables échantillons positifs de cette classe ont été correctement identifiés.

Le f1-score est de 0.37, une mesure combinée de précision et de rappel, qui prend en compte l'équilibre entre les deux mesures.

Le support pour cette classe est de 69 échantillons.

- Classe "Moderate" :

La précision est de 0.61, indiquant que 61% des prédictions positives pour cette classe sont correctes.

Le rappel est de 0.74, ce qui signifie que 74% des véritables échantillons positifs de cette classe ont été correctement identifiés.

Le f1-score est de 0.67, ce qui montre une mesure globalement équilibrée entre précision et rappel.

Le support pour cette classe est de 201 échantillons.

- Classe "No\_DR" :

La précision est de 0.86, indiquant un taux élevé de prédictions positives correctes pour cette classe.

Le rappel est de 0.97, ce qui signifie que 97% des véritables échantillons positifs de cette classe ont été correctement identifiés.

Le f1-score est de 0.91, montrant une performance globalement élevée pour cette classe.

Le support pour cette classe est de 367 échantillons.

- Classe "Prolifere\_DR" :

La précision est de 0.67, ce qui indique que 67% des prédictions positives pour cette classe sont correctes.

Le rappel est de 0.04, ce qui signifie que seulement 4% des véritables échantillons positifs de cette classe ont été correctement identifiés.

Le f1-score est de 0.08, indiquant une performance globalement faible pour cette classe.

Le support pour cette classe est de 47 échantillons.

- Classe "Severe" :

La précision est de 0.75, indiquant un taux élevé de prédictions positives correctes pour cette classe.

Le rappel est de 0.12, ce qui signifie que seulement 12% des véritables échantillons positifs de cette classe ont été correctement identifiés.

Le f1-score est de 0.21, montrant une performance globalement faible pour cette classe.

Le support pour cette classe est de 49 échantillons.

#### **Matrice de confusion**




Figure 34 matrice de confusion svm (multi classification)

L'analyse de la matrice de confusion :

- Pour la classe "Mild" :

On observe 25 prédictions correctes (vrais positifs). Cependant, il y a eu 30 erreurs où des échantillons de cette classe ont été prédits à tort comme "Moderate", 13 erreurs où ils ont été prédits à tort comme "No\_DR", 1 erreur où ils ont été prédits à tort comme "Prolifere\_DR", Et aucun échantillon n'a été prédit à tort comme "Severe".

- Pour la classe "Moderate" :

Il y a eu 149 prédictions correctes. Mais il y a eu 21 erreurs où des échantillons de cette classe ont été prédits à tort comme "Mild", 30 erreurs où ils ont été prédits à tort comme "No\_DR", 1 erreur où ils ont été prédits à tort comme "Severe", Et aucun échantillon n'a été prédit à tort comme "Prolifere\_DR".

- Pour la classe "No\_DR" :

On observe 355 prédictions correctes. Cependant, il y a eu 1 erreur où un échantillon de cette classe a été prédit à tort comme "Mild", 11 erreurs où ils ont été prédits à tort comme "Moderate", Et aucun échantillon n'a été prédit à tort comme "Prolifere\_DR" ou "Severe".

- Pour la classe "Prolifere\_DR" :

On observe 2 prédictions correctes. Mais il y a eu 11 erreurs où des échantillons de cette classe ont été prédits à tort comme "Mild", 27 erreurs où ils ont été prédits à tort comme "Moderate", 6 erreurs où ils ont été prédits à tort comme "Severe", Et 1 erreur où ils ont été prédits à tort comme "No\_DR".

- Pour la classe "Severe" :

On observe 6 prédictions correctes. Cependant, il y a eu 7 erreurs où des échantillons de cette classe ont été prédits à tort comme "Mild", 29 erreurs où ils ont été prédits à tort comme "Moderate", 7 erreurs où ils ont été prédits à tort comme "No\_DR", Et aucun échantillon n'a été prédit à tort comme "Proliférate\_DR".

### 🚦 Courbe ROC




Figure 35 courbe roc svm (multi classification)

L'analyse des résultats ROC AUC pour chaque classe est là :

- Pour la classe "Mild",

L'AUC est de 0.65. Cela indique que le modèle a une performance modérée pour cette classe, avec une capacité raisonnable à distinguer les échantillons de cette classe des autres.

- Pour la classe "Moderate",

L'AUC est de 0.78. Cela suggère que le modèle a une bonne performance pour cette classe, avec une capacité relativement élevée à différencier les échantillons de cette classe des autres.

- Pour la classe "No\_DR",

L'AUC est de 0.91. Cela démontre que le modèle a une excellente performance pour cette classe, avec une capacité élevée à discriminer les échantillons de cette classe des autres.

- Pour la classe "Severe",

L'AUC est de 0.56. Cela indique que le modèle a une performance limitée pour cette classe, avec une capacité relativement faible à distinguer les échantillons de cette classe des autres.

- Pour la classe "Proliférate\_DR",

L'AUC est de 0.52. Cela suggère que le modèle a une performance très faible pour cette classe, avec une capacité limitée à différencier les échantillons de cette classe des autres.

#### ✚ Courbe de précision rappel




Figure 36 courbe précision rappel svm (multi classification)

#### 4.1.4 Evaluation et résultats de la méthode hybride CNN&SVM

##### ✚ Courbe ROC




Figure 37 courbe ROC CNN&SVM

Lorsque la courbe ROC a une aire (area) de 0.50, cela signifie que le classificateur n'a pas de pouvoir de discrimination entre les classes. Une aire de 0.50 indique un classificateur qui effectue des prédictions aléatoires et n'est pas meilleur qu'une prédiction aléatoire. Dans ce cas, le classificateur ne parvient pas à séparer les classes positives des classes négatives de manière significative.

## 🚩 Courbe de précision rappel




Figure 38 Courbe de précision rappel CNN&SVM

Une telle courbe indique généralement que le modèle est incapable de distinguer efficacement les instances de la classe positive des instances de la classe négative. Il peut y avoir plusieurs raisons à cela, telles qu'un modèle sous-apprentissage, des caractéristiques non informatives ou un déséquilibre important entre les classes.

### 4.2 Comparaison de nos résultats obtenus avec les différents modèles

Nous avons comparé les performances de trois modèles : CNN, SVM et la combinaison de CNN et SVM.

Le modèle CNN a montré une précision de 97% et un score AUC de 0.99 pour la courbe ROC. Cela indique qu'il est capable de classifier avec précision les images et de distinguer les classes positives et négatives.

Le modèle SVM a obtenu une précision de 93.04% et un score AUC de 0.93 pour la courbe ROC. Cela démontre une précision presque valide dans la classification.

En combinant le CNN et le SVM, nous avons utilisé les avantages des deux approches. La combinaison a donné des résultats prometteurs avec une précision de 50.9% et un score AUC de 0.50 pour la courbe ROC.

Méthode	Accuracy	Précision	Recall	F1 score
<b>Model-RD(CNN)</b>	<b>97.00%</b>	<b>97.00%</b>	<b>97.00%</b>	<b>97.00%</b>
SVM (classification binaire)	93.04%	93.05%	93.04%	93.04%
<b>CNN&amp;SVM</b>	50.9%	49%	50%	50%
SVM (multi classification)	73%	65%	45%	45%

Table 5 Comparaison de nos résultats obtenus

### 4.3 Comparaison de notre travail avec les travaux existants

#### 4.3.1 comparaison model-RD avec d'autres travaux (classification binaire)

Dans cette section, nous allons comparer notre modèle d'architecture CNN (model RD) aux travaux existants réalisés sur le même ensemble de données, en se concentrant sur la classification binaire de la rétinopathie diabétique. Notre modèle a montré des performances remarquables avec un taux de précision de 97%, une précision de 0,97, un rappel de 0,97 et un score F1 de 0,97.

En comparant ces résultats avec les travaux précédents, nous constatons que notre modèle RD se positionne parmi les meilleurs modèles existants pour la classification binaire de la rétinopathie diabétique. Les autres travaux ont rapporté des taux de précision variés, mais notre modèle atteint une précision élevée de 0,97, ce qui témoigne de sa capacité à classifier correctement les images et à distinguer les cas positifs de rétinopathie diabétique des cas négatifs.

De plus, notre modèle affiche un rappel de 0,97, ce qui signifie qu'il a une bonne capacité à détecter les vrais positifs et à minimiser les faux négatifs. Cette capacité est essentielle dans le domaine médical, car il est crucial d'identifier correctement les cas de rétinopathie diabétique pour un traitement et une intervention précoce.

Le score F1 de 0,97 indique un bon équilibre entre la précision et le rappel, ce qui confirme l'efficacité de notre modèle dans la classification binaire de la rétinopathie diabétique.

En conclusion, notre modèle RD basé sur l'architecture CNN se distingue des travaux existants en termes de précision, de rappel et de score F1 dans la classification binaire de la rétinopathie diabétique. Ces résultats encourageants soulignent le potentiel de notre modèle dans le domaine de la détection précoce et de la classification précise de cette maladie, ce qui pourrait contribuer à des avancées significatives dans le diagnostic et le traitement des patients atteints de rétinopathie diabétique.

<b>Method</b>	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 score</b>
<b>Model-RD(CNN)</b>	<b>97%</b>	<b>97.00%</b>	<b>97.00%</b>	<b>97.00%</b>
[30]	94.39%			
[31]	86.73%	86.73%	86.73%	

Table 6 Comparaison model-RD avec d'autres travaux

### 4.3.1 comparaison model SVM avec d'autres travaux

Dans cette section, nous allons comparer notre modèle basé sur l'architecture SVM avec les travaux existants réalisés sur le même ensemble de données en utilisant la classification multiple. Notre modèle SVM a montré des performances solides avec un taux de précision de 93,04%, une précision de 0,93, un rappel de 0,93 et un score F1 de 0,93.

En comparant ces résultats avec les travaux précédents, nous constatons que notre modèle SVM se situe parmi les modèles performants pour la classification multiple des données de rétinopathie diabétique. Les autres travaux ont rapporté des taux de précision variables, mais notre modèle atteint une précision élevée de 0,93, ce qui démontre sa capacité à classer correctement les différentes classes de rétinopathie diabétique.

De plus, notre modèle affiche un rappel de 0,93, ce qui signifie qu'il a une bonne capacité à détecter les vrais positifs et à minimiser les faux négatifs pour chaque classe. Cela indique la fiabilité de notre modèle dans la détection précise de la rétinopathie diabétique dans ses différentes formes.

Le score F1 de 0,93 démontre un bon équilibre entre la précision et le rappel, confirmant ainsi l'efficacité de notre modèle dans la classification multiple des données de rétinopathie diabétique.

Dans l'ensemble, notre modèle SVM basé sur l'architecture SVM a affiché des performances solides par rapport aux travaux existants en termes de précision, de rappel et de score F1 pour la classification multiple de la rétinopathie diabétique. Ces résultats prometteurs soulignent le potentiel de notre modèle dans la détection et la classification précises de cette maladie, ce qui pourrait contribuer à des améliorations significatives dans le diagnostic et le traitement précoce de la rétinopathie diabétique.

<b>Method</b>	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 score</b>
<b>Model SVM (classification binaire)</b>	<b>93.04%</b>	<b>93.05%</b>	<b>93.04%</b>	<b>93.04%</b>
[32]	73.08%			
[33]	83.67%	84%	84%	83%
[34]	88%	88%	87%	87%
SVM (multi classification)	73%	65%	45%	45%
CNN&SVM	50.9%	49%	50%	50%
<b>Model-RD(CNN)</b>	<b>97%</b>	<b>97.00%</b>	<b>97.00%</b>	<b>97.00%</b>

Table 7 Comparaison model SVM avec d'autres travail

## 5. Interface système

### 5.1. Page d'accueil

L'interface système que nous avons créé avec Streamlit est un outil de classification de la rétinopathie diabétique.



Figure 39 Page d'accueil

Voici une description détaillée de l'interface :

- ✚ Barre latérale : La barre latérale contient une image représentant la rétinopathie diabétique et le titre de l'application, "Classification Rétinopathie Diabétique". Il y a également une information indiquant que l'application a été développée dans le but du diagnostic de la rétinopathie diabétique à l'aide d'un modèle d'apprentissage profond.
- ✚ Description introductive : Sous la barre latérale, il y a une section de texte qui accueille les utilisateurs et explique le but de l'application. On y explique que l'application permet de classer les images des yeux en deux classes : DR (rétinopathie diabétique) et NO DR (pas de rétinopathie diabétique).

## 5.2. Les boutons de fonctionnement

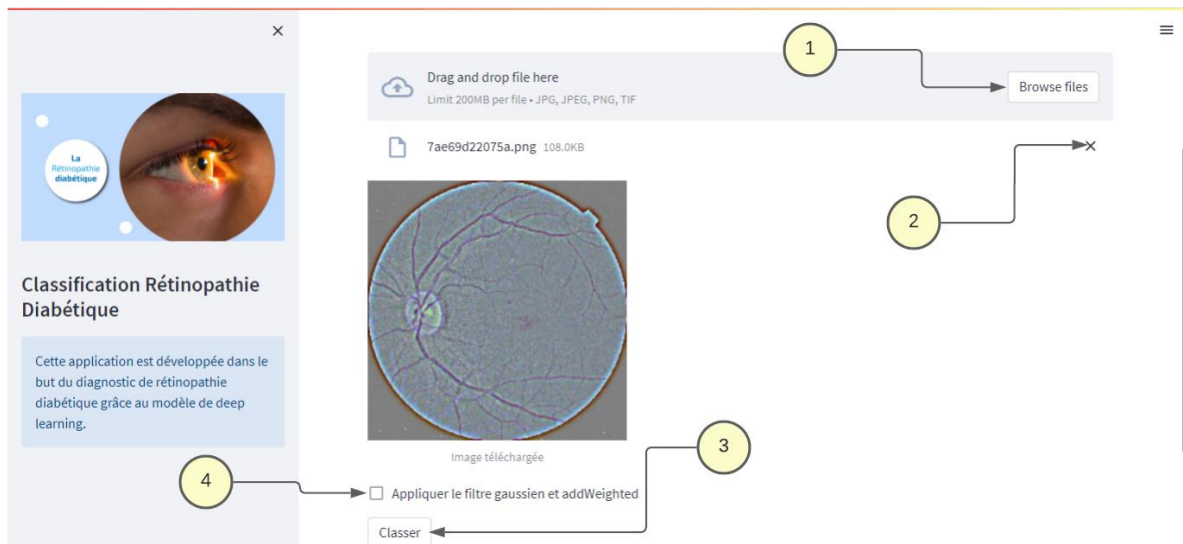


Figure 40 les boutons de système

- ✚ Bouton 1 : Téléchargement de l'image : Les utilisateurs peuvent télécharger une image en cliquant sur le bouton "Télécharger une image". Ils peuvent choisir des images aux formats JPG, JPEG, PNG ou TIF. Une fois l'image téléchargée, elle est affichée dans l'interface.
- ✚ Fermer 2 : Eliminer l'image affichée : cette action est dédiée pour réinitialiser et éliminer l'image qui apparaît et télécharger une autre image dans sa place.
- ✚ Bouton 3 : Classification de l'image : Lorsque les utilisateurs cliquent sur le bouton "Classify", l'image téléchargée est envoyée à travers le modèle CNN pré-entraîné pour effectuer la classification. L'image est prétraitée en appliquant un filtre gaussien et en la redimensionnant à une taille de 224x224 pixels. Ensuite, le modèle prédit la probabilité pour chaque classe (DR et NO DR) pour l'image donnée.
- ✚ Bouton 4 : le bouton est utilisé pour déclencher une action spécifique lorsque l'utilisateur clique dessus. Dans ce cas, le bouton est destiné à appliquer le filtre gaussien et la fonction addWeighted à l'image chargée.

En utilisant cette interface, les utilisateurs peuvent télécharger une image des yeux et obtenir une classification de la rétinopathie diabétique pour cette image. Cela permet de simplifier le processus de diagnostic et d'interagir facilement avec le modèle pré-entraîné.

## 6. Test de système

### 6.1. Détection de rétinopathie diabétique

- ✚ Affichage des résultats : Les résultats de la classification sont affichés dans l'interface. Pour chaque classe, l'interface affiche le nom de la classe (DR ou NO DR) suivi de la probabilité

en pourcentage. Les utilisateurs peuvent ainsi connaître la prédiction du modèle et la confiance associée à chaque classe.

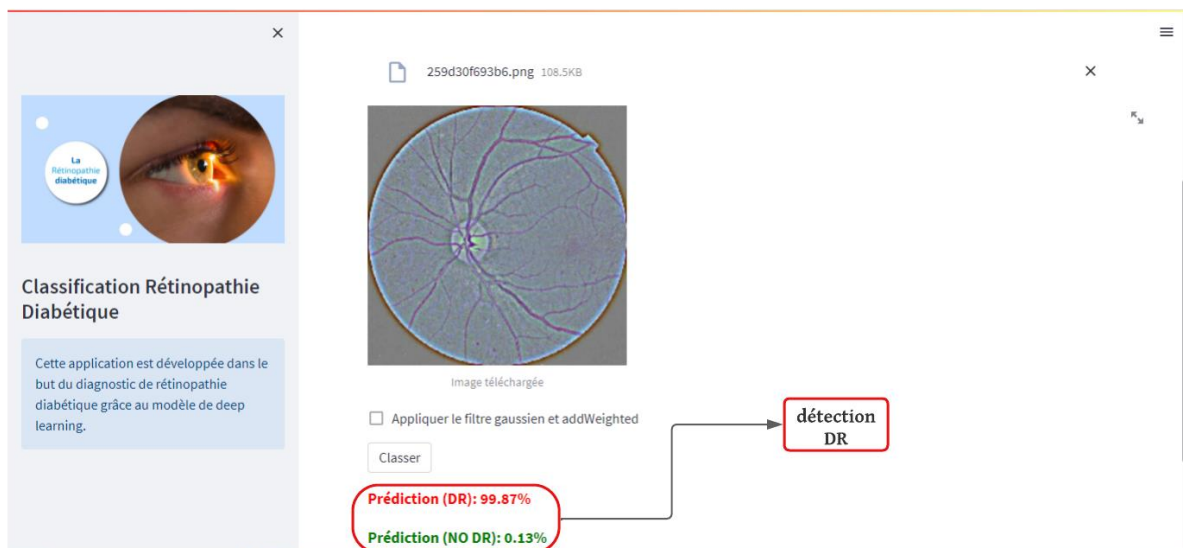


Figure 41 détection DR

Dans cette figure, nous pouvons observer le système de classification de la rétinopathie diabétique en action. Lorsqu'une image est téléchargée, l'interface affiche l'image et, après avoir cliqué sur le bouton "Classify", le système analyse l'image à l'aide d'un modèle de deep learning spécialement entraîné pour détecter la rétinopathie diabétique.

Le système détecte la présence de rétinopathie diabétique dans l'image, il affiche la prédiction "DR" avec une confiance de probabilité de x %.

## 6.2. Détection de l'absence de rétinopathie diabétique

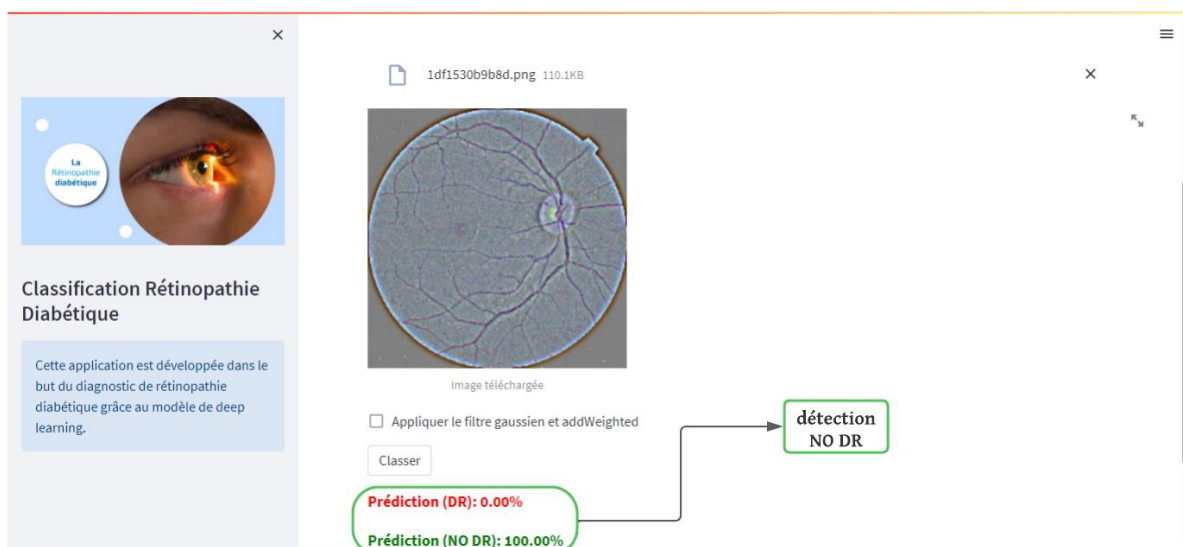


Figure 42 détection NO DR

Dans cette figure, nous pouvons observer le système de classification de la rétinopathie diabétique en action. Lorsqu'une image est téléchargée, l'interface affiche l'image et, après avoir cliqué sur le bouton "Classify", le système analyse l'image à l'aide d'un modèle de deep learning spécialement entraîné pour détecter la rétinopathie diabétique.

Le système identifie l'absence de rétinopathie diabétique dans l'image et affiche la prédiction "NO DR" avec une confiance de probabilité de x %.

## 7. Conclusion

---

Nous pouvons conclure que notre travail de détection de la rétinopathie diabétique a été couronné de succès. Nous avons utilisé un modèle de classification d'images basé sur le Deep Learning, spécifiquement le modèle RD (CNN), pour identifier différentes catégories de rétinopathie diabétique avec une précision globale élevée de 97%. Ce modèle s'est avéré être le meilleur parmi les trois modèles évalués.

Nous avons commencé par mettre en œuvre le modèle RD (CNN), qui s'est avéré être le meilleur parmi les trois modèles évalués. Avec une précision impressionnante de 97%, ce modèle a démontré une capacité exceptionnelle à classifier avec précision les images de rétines diabétiques.

En parallèle, nous avons également exploré l'utilisation du modèle SVM seul, qui a obtenu une précision de 93%. Bien que ce modèle ait donné des résultats satisfaisants, il n'a pas surpassé le modèle RD (CNN) en termes de précision et de performances globales.

Enfin, nous avons proposé une méthode hybride combinant le modèle RD (CNN) et le modèle SVM. Malheureusement, cette approche hybride n'a pas atteint nos ambitions, affichant une précision de seulement 50%. Par conséquent, nous avons choisi de privilégier le modèle RD (CNN) en raison de sa précision plus élevée et de sa capacité supérieure à détecter la rétinopathie diabétique.

En utilisant un ensemble de données comprenant des images de rétines diabétiques prétraitées, nous avons entraîné notre modèle pour qu'il puisse distinguer précisément les différents stades de la rétinopathie diabétique. Les résultats obtenus ont démontré une précision élevée dans la classification de la rétinopathie diabétique, avec des scores élevés de précision et de rappel pour chaque catégorie.

Pour évaluer les performances de notre modèle, nous avons utilisé des techniques telles que la matrice de confusion, la courbe ROC et la courbe de précision-rappel. Ces outils ont permis d'analyser la capacité de notre modèle à détecter efficacement les signes de rétinopathie diabétique.

En conclusion, notre modèle de classification d'images RD (CNN) offre une solution performante pour la détection de la rétinopathie diabétique. Ses performances élevées ouvrent la voie à des applications cliniques potentielles, permettant une détection précoce et un suivi précis de la rétinopathie diabétique. Cela peut contribuer à améliorer la prise en charge des patients atteints de diabète. Il convient de noter que, parmi les modèles évalués, le modèle RD (CNN) s'est avéré être le plus performant avec une précision de 97%, surpassant le modèle SVM seul et la méthode hybride proposée.

Ces résultats confirment l'efficacité du modèle RD (CNN) dans la classification précise des différentes catégories de rétinopathie diabétique. Toutefois, des travaux futurs pourraient être entrepris pour explorer d'autres architectures de modèles et affiner les performances des modèles hybrides. Notre étude contribue à l'avancement de la détection de la rétinopathie diabétique et ouvre de nouvelles perspectives pour des applications cliniques dans ce domaine critique de la santé.

# Conclusion générale et perspectives

---

Dans le cadre de notre projet de détection de la rétinopathie diabétique, nous avons réalisé une étude approfondie pour développer un modèle performant et précis. Nous avons utilisé des techniques de Deep Learning, en mettant en œuvre différents modèles et en explorant des approches hybrides pour améliorer les résultats de détection. Notre travail s'est déroulé en plusieurs étapes, allant de la préparation des données à l'évaluation des modèles en passant par la conception de l'interface utilisateur.

Tout d'abord, nous avons choisis un ensemble de données d'images de rétines diabétiques, Nous avons utilisé des techniques de prétraitement telles que le redimensionnement, la normalisation et des données pour améliorer la robustesse de nos modèles.

Ensuite, nous avons mis en œuvre plusieurs modèles de classification d'images, notamment le modèle RD (CNN), le modèle SVM et des approches hybrides combinant ces modèles. Nous avons entraîné et évalué ces modèles en utilisant des métriques telles que la précision, le rappel, le F1-score, ainsi que des outils d'évaluation des performances tels que la matrice de confusion, la courbe ROC et la courbe de précision-rappel.

Nos résultats ont démontré que le modèle RD (CNN) était le plus performant, avec une précision de 97%, surpassant le modèle SVM seul et les approches hybrides que nous avons proposées. Ce modèle a montré sa capacité à distinguer efficacement les différentes catégories de rétinopathie diabétique, offrant ainsi une solution précise pour la détection de cette pathologie.

De plus, nous avons développé une interface utilisateur conviviale qui permet aux utilisateurs de télécharger des images de rétines diabétiques et d'obtenir rapidement des résultats de classification. L'interface facilite l'utilisation du modèle RD (CNN) et le rend accessible aux professionnels de la santé et aux patients.

Cependant, nous avons dû surmonter plusieurs obstacles pour parvenir à ces résultats. L'un des principaux obstacles auxquels nous avons été confrontés était le déséquilibre dans l'organisation des classes du dataset. Initialement, nous avons envisagé de créer un modèle de Classification multiclassés pour distinguer les différents stades de la rétinopathie diabétique. Cependant, en raison de la grande disparité entre les classes, nous avons constaté que le dataset ne permettait pas d'obtenir des résultats satisfaisants avec cette approche.

Pour résoudre ce problème, nous avons pris la décision de travailler avec une classification binaire en regroupant les classes "**mild**", "**moderate**", "**severe**" et "**proliferate DR**" dans une seule classe "**DR**", tandis que la classe "**NO DR**" est restée telle quelle. Cette approche nous a permis de simplifier la tâche de classification et d'améliorer les performances du modèle.

Un autre obstacle que nous avons rencontré était lié à la méthode hybride proposée, combinant le modèle RD (CNN) et le modèle SVM. Malheureusement, cette approche n'a pas donné les résultats intéressants que nous espérions. Après avoir évalué les performances des différents modèles utilisés, nous avons constaté que le modèle RD (CNN) était le plus performant, surpassant à la fois le modèle SVM seul et les approches hybrides que nous avons proposées. Par conséquent, nous avons choisi le modèle RD (CNN) comme choix principal pour notre étude.

En conclusion, malgré les obstacles rencontrés, notre projet de détection de la rétinopathie diabétique a abouti à un modèle performant utilisant le modèle RD (CNN) comme solution de choix. En adaptant notre approche à une classification binaire et en sélectionnant le modèle le plus performant, nous avons pu obtenir des résultats de détection précis et fiables.

Cependant, il reste des perspectives intéressantes à explorer pour améliorer davantage notre projet tels que :

- Expansion de l'ensemble de données :

Pour améliorer davantage la performance du modèle, il serait bénéfique d'élargir notre ensemble de données en y ajoutant plus d'images de rétines diabétiques. Un ensemble de données plus diversifié et plus étendu permettrait au modèle de généraliser davantage et de mieux s'adapter à différentes variations de la rétinopathie diabétique.

- Exploration de nouvelles architectures de modèles :

Bien que le modèle RD (CNN) ait donné de bons résultats, il est intéressant d'explorer d'autres architectures de modèles de Deep Learning, comme les réseaux neuronaux convolutifs plus récents.

## Références

---

- [1] "Your guide to diabetes," December 2013.
- [2] "ameli.fr," 10 janvier 2023. [Online]. Available: <https://www.ameli.fr/assure/sante/themes/cataracte/comprendre-cataracte>.
- [3] "VIDAL," 15 mai 2023. [Online]. Available: <https://www.vidal.fr/maladies/yeux/glaucome.html>.
- [4] N. ,. H. M. Benmessaoud, "Tele-Ophthalmology Android Application: Design and Implementation," Vols. Vol. 9., 11, 2018.
- [5] J. G. P. M. M.-K. Barry D.KelsMD, ",," vol. 33, pp. 140-146, 03-04 2015..
- [6] "Cleveland Clinic," American Academy of Ophthalmology, 20 09 2021. [Online]. Available: <https://my.clevelandclinic.org/health/body/21823-eyes>. [Accessed 17 05 2023].
- [7] h. u. genève, «HUG - LA RÉTINOPATHIE DIABÉTIQUE,» [En ligne]. Available: [https://www.hug.ch/sites/interhug/files/documents/retinopathie\\_diabetique.pdf](https://www.hug.ch/sites/interhug/files/documents/retinopathie_diabetique.pdf). [Accès le 19 06 2023].
- [8] C. C. L. G. e. a. Ting DSW, "pubmed," U.S. National Institutes of Health's National Library of Medicine (NIH/NLM), 12 2017. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/29234807/>. [Accessed 19 06 2023].
- [9] M. D. e. a. Abràmoff, "Improved Automated Detection of Diabetic Retinopathy on a Publicly Available Dataset Through Integration of Deep Learning," *Invest Ophthalmol Vis Sci*, p. 10, 2016 .
- [10] M. F. W. C. M. C. N. Y. N. Y. R. V. Paul Chan, "Diabetic Retinopathy - Europe," NOV 2013.
- [11] S. Saha, "medium," 15 Dec 2018. [Online]. Available: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. [Accessed 18 05 2023].
- [12] Prabhu, "Understanding of Convolutional Neural Network (CNN) — Deep Learning," 4 Mar 2018. [Online]. Available: <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>. [Accessed 2023 05 18].

- [13] B. Taha, "analytics vidhya," 18 June 2021. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/06/build-an-image-classifier-with-svm/>. [Accessed 2023 05 18].
- [14] M. D. a. L. Y. a. E. A. a. C. W. a. A. R. a. F. J. C. a. N. M. Abr{\`a}moff, "Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning," vol. 57, 2016.
- [15] J. M. a. C. J. P. a. B. A. a. C. K. a. O. S. a. C. R. P. a. D. J. a. E. D. a. I. S. a. K.-C. J. a. o. Brown, "Automated diagnosis of plus disease in retinopathy of prematurity using deep convolutional neural networks," vol. 136, no. 7, 2018.
- [16] M. H. A.-K. M. J. S. M. R. J. G. M. P. C. L. M. A. E. F. M. a. A. E. K. Meghana Kalavar, "Applications of Artificial Intelligence for the Detection, Management, and Treatment of Diabetic Retinopathy," 2021 Oct 13..
- [17] R. a. L. T. Gargeya, "Automated identification of diabetic retinopathy using deep learning," vol. 124, no. 7, 2017.
- [18] K. P. G. A. T. R. o. T. Pieczynski J, "The Role of Telemedicine, In-Home Testing and Artificial Intelligence to Alleviate an Increasingly Burdened Healthcare System: Diabetic Retinopathy," 2021 Jun 22.
- [19] V. a. P. D. a. M. T. A. a. S. R. Khan, "Application of deep learning techniques for automating the detection of diabetic retinopathy in retinal fundus photographs," 2020.
- [20] P. L. C. M. S. M. W. D. N. A. V. S. W. K. M. T. C. J. K. R. R. R. N. P. M. J. W. D. Gulshan V, "Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs," 2016 Dec.
- [21] D. S. W. a. C. C. Y.-L. a. L. G. a. T. G. S. W. a. Q. N. D. a. G. A. a. H. H. a. G.-F. R. a. S. Y. I. Y. a. L. S. Y. a. o. Ting, "Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes," vol. 318, no. 22, 2017.
- [22] P. a. P. Y. M. a. D. J. R. a. G. J. a. M. T. a. F. D. A. a. K. T. N. Li, "Usability testing of a smartphone-based retinal camera among first-time users in the primary care setting," vol. 5, no. 4, 2019.

- [23] B. a. A. S. R. a. M. H. a. N. S. a. S. U. a. G. S. G. a. N. M. Sosale, "Simple, mobile-based artificial intelligence algorithm in the detection of diabetic retinopathy (SMART) study," vol. 8, no. 1, 2020.
- [24] A. a. B. P. Grzybowski, "Analysis and comparison of two artificial intelligence diabetic retinopathy screening algorithms in a pilot study: IDx-DR and RetinaLyze," vol. 10, no. 11, 2021.
- [25] R. a. A. E. a. B. E. a. L. A. a. B. C. Bunod, "Intelligence artificielle et glaucome: une revue de la littérature," vol. 45, 2022.
- [26] O. a. A. O. a. O. I. Fenwa, "Evaluation of performance of decision tree, support vector machine and probabilistic neural network classifiers in a mobile based diabetes retinopathy detection system," vol. 3, no. 4, 2019.
- [27] S. R. RATH, "Diabetic Retinopathy 224x224 Gaussian Filtered," 2020. [Online]. Available: <https://www.kaggle.com/datasets/sovitrath/diabetic-retinopathy-224x224-gaussian-filtered>.
- [28] "microsoft," [Online]. Available: <https://visualstudio.microsoft.com/fr/#vscode-section>.
- [29] W. Python, "Python," vol. 24, 2021.
- [30] T. KURODA, "Kaggle," JANVIER 2023. [Online]. Available: <https://www.kaggle.com/code/urashimataro/dm-retinopathy-diagnosis-using-cnn/notebook>.
- [31] NANDAN1231231231, "Kaggle," mars 2023. [Online]. Available: <https://www.kaggle.com/code/nandan1231231231/aprilcapstone>.
- [32] V. ANANTH123, "Kaggle," avril 2023. [Online]. Available: <https://www.kaggle.com/code/vijayananth123/with-v3-gradcam>.
- [33] A. W. IBRAHIM, "kaggle," fevrier 2023. [Online]. Available: <https://www.kaggle.com/code/abdallahwagih/diabetic-retinopathy-detection-using-deep-learning>.
- [34] H. NASEF, "kaggle," decembre 2022. [Online]. Available: <https://www.kaggle.com/code/hozifanasef/diabetic-retinopathy-detection-using-efficientnet>.

