

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université A/Mira de Béjaia
Faculté des Sciences Exactes
Département d'Informatique

DE MASTER RECHERCHE

En
Informatique

Option
Intelligence Artificielle

Thème

Utilisation des Réseaux Antagonistes Génératifs
pour le traitement des images médicales
ophtalmologiques cas : Rétinopathie diabétique

Présenté par :
Mlle BENADJAUD Imene

Soutenu le 22 Septembre 2022 : devant le jury composé de

Président	AMROUN Kamal
Examineur	BOUCHEBBAH Fatah
Encadreur	AIT KACI AZZOU Samira
Co-encadreur	BOULAHROUZ Djamila

Béjaia, septembre 2022.

Remerciements

Au terme de ce travail, je tiens à exprimer ma profonde gratitude et mes sincères
remerciements.

Je remercie le dieu le tout puissant de m'avoir donné la force, la volonté de donner le meilleur
de moi-même et le courage de mener ce travail.

Je tiens en premier lieu à exprimer ma profonde reconnaissance à mon encadreur Mme AIT
KACI AZZOU Samira, pour son encadrement au sens propre du terme, puis pour m'avoir fait
confiance et pour m'avoir accompagné, encouragé et conseillé au cours de mon cursus.
Je tiens à remercier très chaleureusement mon Co-encadreur Mme Boulahrouz Djamila pour sa
collaboration importante pendant la rédaction de ce mémoire, ses encouragements et ses
conseils.

Je tiens également à remercier les membres du jury d'avoir consacré leurs temps à la lecture et
à la correction de ce mémoire.

Mes remerciements les plus vifs vont tout particulièrement à mes parents, mes frères et mon
francé en qui j'ai puisé tout le courage, la volonté et la confiance, je leur serai éternellement
reconnaissante.

Enfin, Je n'omettrai jamais d'exprimer toute ma gratitude à tous les membres du département
d'Informatique de l'Université de Béjaia, que ce soit enseignants ou cadres administratifs, qui
de près ou de loin n'ont épargné aucun effort pour que notre formation et nos travaux se
terminent dans de bonnes conditions.

Dédicaces

Je dédie ce Modeste travail :

À mes chers parents, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études ;

À mes chers frères Idir, Shérif et Zizou pour leurs encouragements permanents, et leur soutien moral ;

À mon cher fiancé Nassim, pour la patience et le soutien dont il a fait preuve pendant toute la durée de ce travail et à qui je voudrais exprimer mes affections et mes gratitude ;

À ma belle famille ;

À ma belle sœur Salima ;

À mes amies Celia, Syla, Siham, Dina, Lydia et surtout Lynda ;

A toute ma famille pour leur soutien tout au long de mon parcours universitaire,
Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien
infaillible,

Merci d'être toujours là pour moi.

Table des matières

Table des matières	ii
Table des figures	v
Liste des abréviations	1
Introduction générale	2
1 Apprentissage automatique et Réseaux Antagonistes Génératifs (RAGs)	5
1.1 Introduction	5
1.2 Cas d'utilisation de l'apprentissage automatique	5
1.3 Modes d'apprentissage	6
1.3.1 Apprentissage supervisé	6
1.3.2 Apprentissage par renforcement	7
1.3.3 Apprentissage non-supervisé	7
1.4 Réseaux de Neurons Artificiels (RNA)	8
1.4.1 Perceptron	8
1.4.2 Réseaux de Neurons Profonds	9
1.4.3 Réseaux de Neurons Convolutifs (CNN)	10
1.4.4 Réseaux Antagonistes Génératifs (RAGs)	12
1.4.4.1 Définition	12
1.4.4.2 Architecture et fonctionnement du GAN	13
1.4.4.2.1 Modèle du générateur	14
1.4.4.2.2 Modèle du discriminateur	15
1.4.4.3 Différents types de GANs	16
1.4.4.4 Domaines d'applications du GAN	22
1.4.4.5 Avantages et inconvénients	25
1.4.5 Fonctions d'activation	25
1.4.6 Fonction de perte	28
1.4.7 Propagation arrière	28
1.5 Conclusion	28

2	Utilisation des GANs pour le traitement des images ophtalmologiques	29
2.1	Introduction	29
2.2	Utilité des GANs dans le domaine médical	30
2.2.1	Segmentation	30
2.2.2	Augmentation de données	32
2.2.3	Débruitage et super-résolution	34
2.2.4	Transfert de domaine	36
2.2.5	Prédiction post-intervention	38
2.2.6	Extraction de caractéristiques	38
2.2.7	Autres applications	39
2.3	Conclusion	39
3	Conception et réalisation d'un modèle GAN	40
3.1	Introduction	40
3.2	Rétinopathie diabétique	40
3.3	Architecture du modèle GAN proposé	44
3.3.1	Architecture du générateur	45
3.3.2	Architecture du discriminateur	46
3.4	Bases de données utilisées	47
3.5	Apprentissage	47
3.6	Réalisation	48
3.6.1	Environnement de développement	51
3.6.1.1	Python	51
3.6.1.2	OpenCV	51
3.6.1.3	NumPy	51
3.6.1.4	Matplotlib	52
3.6.1.5	TensorFlow	52
3.6.1.6	Keras	52
3.6.1.7	Google Colaboratory	52
3.6.2	Implémentation	53
3.7	Conclusion	55
	Conclusion générale	56
	Bibliographie	57

Table des figures

1.1	Sous-ensembles de l'intelligence artificielle [91]	6
1.2	Apprentissage supervisé [26]	7
1.3	Apprentissage non-supervisé [26]	7
1.4	Perceptron [7]	8
1.5	Réseau de neurones multicouches [42]	9
1.6	architecture d'un réseau de neurone convolutif. [16]	10
1.7	La couche de convolution [29]	11
1.8	La couche pooling [44]	11
1.9	Couche entièrement connecté (Fully Connected) [8]	12
1.10	Réseaux Antagonistes Génératifs [15].	13
1.11	Exemple d'architecture de modèle de réseau antagoniste génératif [12]	13
1.12	Exemple de modèle de générateur GAN. [12]	15
1.13	Exemple de modèle du Discriminateur GAN. [12]	15
1.14	Architecture de CycleGAN [99]	16
1.15	Exemple de traduction d'image à image non appariée à l'aide de Cycle GAN[14]	16
1.16	Architecture de DCGAN [13]	17
1.17	Exemple d'images générées par DCGAN [13]	17
1.18	Architecture de CGAN[99]	18
1.19	Exemple d'utilisation de CGAN[61]	18
1.20	Architecture de Pix2pix GAN[4]	19
1.21	Exemple d'utilisation de Pix2pix GAN[4]	19
1.22	Représentation des modèles Encodeur-Decodeur Generateur et U-Net Generateur[4]	20
1.23	Architecture de ACGAN [99]	21
1.24	Exemple d'images générées par ACGAN [13]	21
1.25	Exemple d'images générées par le GAN [5]	22
1.26	Exemple textes en images [5]	22
1.27	Exemple de Vieillessement du visage [5]	23
1.28	Exemple image vers image [5]	23
1.29	Exemple de génération d'image haute résolution [5]	24
1.30	Exemple Parties manquantes complétées [5]	24
1.31	Fonction d'activation sigmoïde [3]	26

1.32	Fonction d'activation ReLU [3]	26
1.33	Fonctions d'activations Leaky ReLU et Parametric ReLU [3]	27
1.34	Fonctions d'activations Softmax [3]	28
3.1	Description de l'anatomie de l'oeil[90].	41
3.2	Microanévrismes[83].	42
3.3	Rétinopathie diabétique non proliférante (RDNP) modérée[1]	42
3.4	Rétinopathie diabétique non proliférante sévère[1]	43
3.5	Rétinopathie diabétique proliférante (RDP)[1]	43
3.6	Architecture générale proposée	44
3.7	Architecture du Générateur	45
3.8	Architecture du Discriminateur	46
3.9	Architecture détaillée du Discriminateur	46
3.10	Comparaison vaisseaux rétiniens	50
3.11	Comparaison microanévrismes	50
3.12	Comparaison bruit	50

Liste des abréviations

Liste des abréviations

ANN	Artificial Neural Network
CNN	Convolutional Neural Network
DL	Deep Learning
GAN	Generative Adversarial Network
IA	Intelligence Artificielle
ML	Machine Learning
OCT	Optical Coherence Tomography
RD	Rétinopathie Diabétique
SRGAN	Super Resolution Generative Adversarial Network

Introduction générale

Historiquement, le concept d'Intelligence Artificielle (IA) a fait son apparition dès la fin des années 50, avec un algorithme rudimentaire de classification binaire appelé “perceptron”. Désormais d’une très haute complexité, l’IA, discipline en constante évolution, façonne la société de demain. Elle se définit traditionnellement comme l’ensemble des théories et des techniques mises en œuvre dans le but de réaliser des machines capables de simuler ou dépasser l’intelligence humaine. Parmi ces techniques, on retrouve le Machine Learning, également appelé “Apprentissage automatique”, développé à partir des années 70. Ce dernier consiste à doter les ordinateurs de la capacité d’apprendre à réaliser une tâche à partir d’exemples, sans y avoir été explicitement programmé. Parmi les méthodes existantes, le Deep Learning (DL) ou apprentissage en profondeur qui est entièrement basée sur des réseaux de neurones artificiels est considéré comme la prochaine étape de l’évolution du ML inculquant aux machines la manière de prendre leurs décisions de façon précise sans l’intervention de l’expert humain.

Dans le monde scientifique du Deep Learning les réseaux GANs (Generative Adversarial Network) font de plus en plus de bruit, ces réseaux antagonistes génératifs (GANs) sont l’une des technologies modernes du DL qui offrent beaucoup de potentiel dans de nombreux cas d’utilisation, de la création de nouvelles images et de l’augmentation de la voix à la fourniture de diverses applications dans les industries médicales et autres.

Conçus en 2014 par Ian Goodfellow [50], et certains de ses collègues, les GANs sont des réseaux de neurones profonds uniques capables de générer de nouvelles données similaires à celles sur lesquelles ils sont formés, avec leur composition de deux réseaux de neurones en compétition pour produire des prédictions plus précises telles que des images, de la musique unique, des dessins, etc. Ils s’affrontent dans un jeu à somme nulle qui fait qu’un agent perd la partie tandis que l’autre la gagne [39].

L’analyse d’images médicales est une application importante de l’apprentissage profond, qui devrait réduire considérablement la charge de travail des médecins, contribuant ainsi à des systèmes de santé plus durables. Cependant, la plupart des méthodes d’IA actuelles pour l’analyse d’images médicales sont basées sur un apprentissage supervisé, ce qui nécessite beaucoup de données annotées. Le nombre d’images médicales disponibles est généralement faible et l’acquisition d’anno-

tations d'images médicales est un processus coûteux, cette rareté chronique des données étiquetées due à la confidentialité du patient est la cause principale de la taille réduite des datasets dans ce domaine, ce qui fait que les techniques les plus élaborées de ML utilisées pour la détection, la classification voire la prédiction n'aboutissent pas à des résultats très fiables. Par ailleurs, les GANs qui ont fait leur preuve quant à la génération d'images de synthèse à partir d'un bruit, représentent une bonne alternative au problème de la rareté des données médicales. En effet, les réseaux antagonistes génératifs (GANs), une méthode non supervisée qui est devenue très populaire ces dernières années, peuvent simuler la distribution de données réelles et reconstruire des données réelles approximatives. Ainsi, le GAN ouvre de nouvelles voies passionnantes et pourrait être exploité pour la génération d'images médicales, en augmentant le nombre d'images disponibles pour les méthodes d'apprentissage en profondeur. Les données générées peuvent résoudre le problème de données insuffisantes ou de données déséquilibrées. La formation contradictoire est une autre contribution du GAN à l'imagerie médicale qui a été appliquée à de nombreuses tâches, telles que la classification, la segmentation, la super résolution ou la détection.

Comparé à d'autres techniques d'analyse d'images médicales [75], le GAN en est encore à ses balbutiements et le nombre d'ouvrages connexes disponibles dans la littérature est relativement faible, mais il a un potentiel énorme. L'application du GAN aux images médicales a commencé en 2016, lorsque seul un article sur le sujet a été publié[108]. Depuis 2017, il y a eu des études plus pertinentes, de sorte que les articles sur le GAN dans les images médicales au cours des cinq dernières années ont été analysés et résumés en termes de direction d'application, de méthodes et d'autres aspects.

En ce qui nous concerne, nous avons choisi de travailler sur les images ophtalmologiques car c'est un domaine qui souffre de plus d'insuffisance de données étiquetées par rapport aux autres, et nous nous intéressons plus particulièrement à la Rétinopathie Diabétique (RD) qui est une complication tardive liée au diabète. Les personnes atteintes de cette pathologie se voient généralement subir des pertes visuelles graves à cause du dépistage tardif. Ces déficiences visuelles peuvent être plus ou moins graves selon le stade de la pathologie, conduisant dans le pire des cas à une cécité chez les malades. La progression vers une déficience visuelle peut être ralentie ou évitée, si une RD est détectée à temps. Toutefois, cela peut être difficile car la maladie présente souvent peu de symptômes jusqu'à ce qu'il soit trop tard pour fournir un traitement efficace. Le processus de détection de la maladie est manuel et fastidieux, cela nécessite un ophtalmologiste qualifié pour évaluer la photographie numérique de fond scopie, mais souvent lorsque la maladie est diagnostiquée il est souvent trop tard, le patient aurait subi des pertes irréversibles.

Le but est alors de pouvoir aider les médecins pour la détection de la maladie et sa classification au moment opportun en proposant une architecture basée sur les GANs qui permettra, en plus d'augmenter les données à partir d'une image réelle, de la prétraiter pour améliorer sa qualité et visuelle pour une meilleure classification et un bon diagnostic.

Pour présenter notre travail, nous avons divisé notre mémoire en trois chapitres principaux comme suit :

Dans le premier chapitre, nous effectuons un aperçu sur l'apprentissage automatique et plus particulièrement les différents réseaux de neurones profonds à savoir le perceptron, les CNNs et les GANs.

Dans le chapitre qui suit, nous verrons comment les GANs ont été exploités pour le traitement des images médicales et plus particulièrement des images ophtalmologiques.

Dans le dernier chapitre, nous définirons la maladie de RD et nous présenterons l'architecture du GAN que nous proposons ainsi que ses résultats pour la détection et la classification automatique de la RD.

Nous terminerons ce mémoire par une conclusion générale qui résume l'essentiel de notre travail.

Apprentissage automatique et Réseaux Antagonistes Génératifs (RAGs)

1.1 Introduction

L'apprentissage automatique est une branche de l'intelligence artificielle (IA) et de l'informatique qui utilise principalement des données et des algorithmes pour imiter la manière dont les être humains apprennent, en améliorant progressivement sa précision (voir Figure 1.1). En 1956, Arthur Samuel définit l'apprentissage automatique (machine learning) comme un « domaine d'étude qui donne aux ordinateurs la capacité d'apprendre sans être explicitement programmé »[92].

On peut alors différencier un programme « classique » qui reçoit des données en entrée et utilise des procédures spécifiquement programmées pour générer des résultats en sortie, d'un programme de machine learning qui utilise des données en entrées et les résultats obtenus en sortie pour définir des procédures [26]. Prenons l'exemple d'une société de vente en ligne qui souhaite connaître les 3 produits les plus vendus d'une année terminée. Il suffit d'appliquer un algorithme classique, à savoir une simple addition, il n'est donc pas nécessaire d'utiliser un algorithme d'apprentissage. Cependant, si cette même société souhaite connaître les 3 produits qui seront probablement les plus vendus de l'année en cours, il n'est alors plus possible d'appliquer une simple addition étant donné que les informations sont incomplètes. Il est alors possible d'utiliser un algorithme d'apprentissage automatique sur la base de l'historique des ventes effectuées pour générer un modèle prédictif permettant de répondre à ce besoin.

1.2 Cas d'utilisation de l'apprentissage automatique

L'apprentissage automatique peut servir à résoudre 3 types de problèmes [26] :

- Ce que l'on ne sait pas (encore) résoudre ;
- Ce que l'on sait résoudre, mais dont on ne se sait pas formaliser en termes algorithmiques comment nous les résolvons (par exemple la reconnaissance d'images, la compréhension du langage naturel) ;

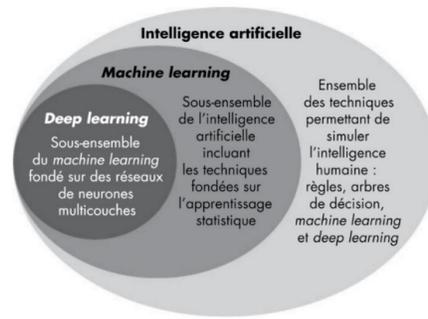


FIGURE 1.1 – Sous-ensembles de l’intelligence artificielle [91]

- Ce que l’on sait résoudre, mais avec des procédures beaucoup trop gourmandes en ressources informatiques.

Le machine learning est donc utilisé lorsque les données sont abondantes mais que les connaissances sont peu accessibles ou peu développées [26].

Les algorithmes d’apprentissage peuvent aussi aider les humains à apprendre sur les données en révélant l’importance relative de certaines informations ou la façon dont elles interagissent entre elles pour résoudre un problème particulier [26].

1.3 Modes d’apprentissage

L’apprentissage-machine est l’ensemble des méthodes permettant d’entraîner un système, au lieu de le programmer explicitement. Il existe 3 formes d’apprentissages [26] :

- Apprentissage supervisé,**
- Apprentissage par renforcement et**
- Apprentissage non-supervisé.**

1.3.1 Apprentissage supervisé

L’apprentissage supervisé entraîne le système à accomplir une tâche à partir d’exemples d’entrée et de sortie correspondante [72].

Stéphane Roder nous apprend que 90% de l’intelligence artificielle de ces dernières années est fondée sur cette technique d’apprentissage [91] .

On utilise les exemples du passé (observations et étiquettes) pour en déduire une fonction de prédiction, le modèle prédictif, qui va nous permettre de généraliser notre connaissance pour une utilisation future [91].

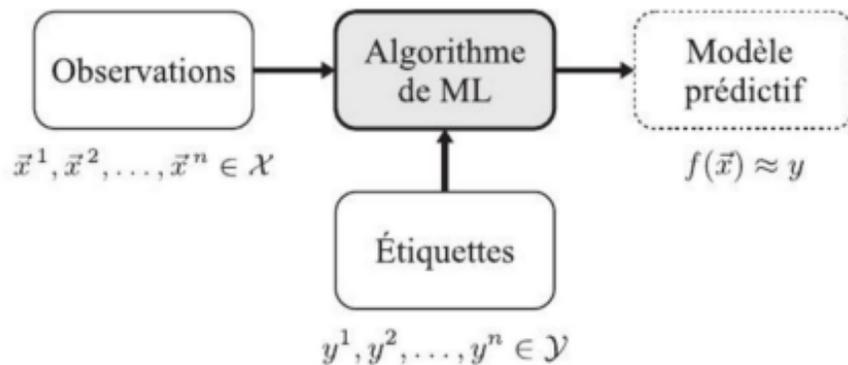


FIGURE 1.2 – Apprentissage supervisé [26]

1.3.2 Apprentissage par renforcement

L'apprentissage par renforcement entraîne le système par interaction avec un environnement par essais et erreurs [72]. En retour de ces actions, le système obtient une récompense, qui peut être positive si l'action était un bon choix, ou négative dans le cas contraire [26]. Les applications principales de l'apprentissage par renforcement se trouvent dans les jeux, comme le go ou les échecs, et dans la robotique. L'apprentissage consiste à définir une stratégie permettant d'obtenir systématiquement la meilleure récompense possible [26].

1.3.3 Apprentissage non-supervisé

Dans le cas de l'apprentissage non supervisé ou auto-supervisé, le système découvre les interdépendances entre les variables d'entrée sans être entraîné pour une tâche particulière [72].



FIGURE 1.3 – Apprentissage non-supervisé [26]

1.4 Réseaux de Neurones Artificiels (RNA)

Les réseaux de neurones sont des modèles d'apprentissage automatique capables de représenter une relation entre des données d'un espace X et un espace de sortie Y . Ils sont utilisés dans de nombreux domaines, comme la vision assistée par ordinateur, le traitement du langage naturel l'analyse audio... L'unité de calcul de base est le neurone. Celui-ci prend en entrée plusieurs signaux et les interprète pour envoyer un nouveau signal vers d'autres neurones ou vers la sortie du réseau de neurones, c'est-à-dire la sortie du modèle. Il existe de nombreuses architectures pour construire des réseaux de neurones. Pour introduire les réseaux de neurones, nous allons commencer par présenter un modèle composé d'un seul neurone, appelé modèle du perceptron. Celui-ci va nous permettre de mettre en évidence les mécanismes de base de tout réseau de neurones.

1.4.1 Perceptron

le perceptron est un réseau de neurones composé de seulement un neurone, qui prend en entrée n données binaires. Chacune de ses entrées i est pondérée par un poids noté w_i . Le neurone peut prendre les états 1 ou 0 (respectivement actif ou non-actif) en fonction de ses entrées pondérées et d'un biais noté b (voir Figure 1.4). La sortie du perceptron peut être interprétée comme la probabilité que le neurone s'active en fonction de l'entrée.

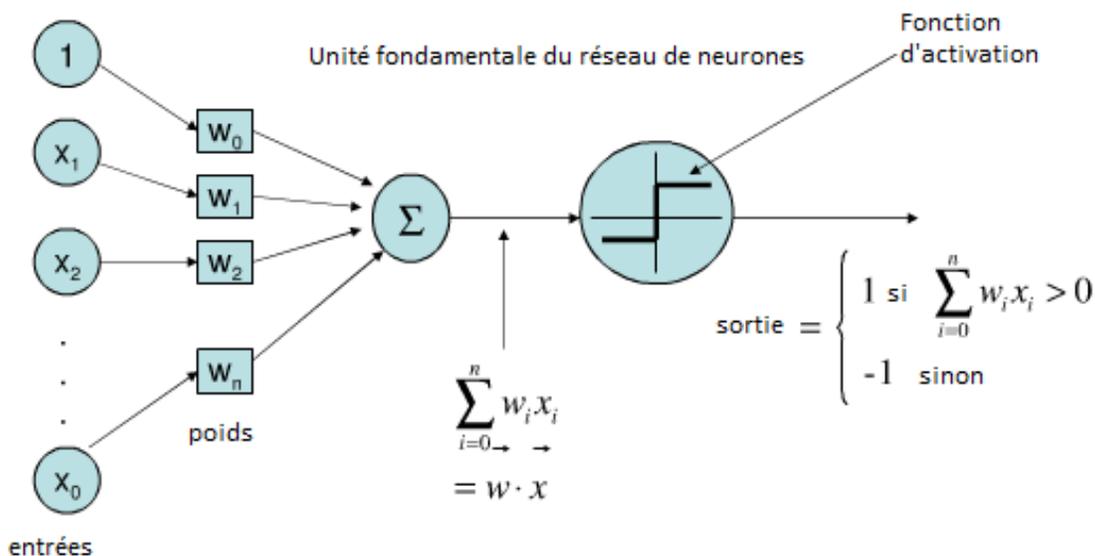


FIGURE 1.4 – Perceptron [7]

1.4.2 Réseaux de Neurons Profonds

Les réseaux de neurones profonds sont composés d'une multitude de neurones interconnectés et organisés en couches successives. Ils sont polyvalents, puissants et extensibles, ce qui les rend parfaitement adaptés aux tâches d'apprentissage automatique complexes, comme la classification de milliards d'images, la reconnaissance vocale[48].

On parle de deep learning car les réseaux de neurones multicouches permettent l'apprentissage grâce à des représentations de données à de multiples niveaux d'abstraction [27].

Un réseau de neurones profond peut être représenté par un graphe dans lequel chaque noeud représente un neurone. Les arcs orientés représentent les relations entre chaque neurone. La couche d'entrée est chargée de réceptionner les données d'entrées. Les couches cachées effectuent les différents traitements et la couche de sortie livre les résultats (voir Figure 1.5).

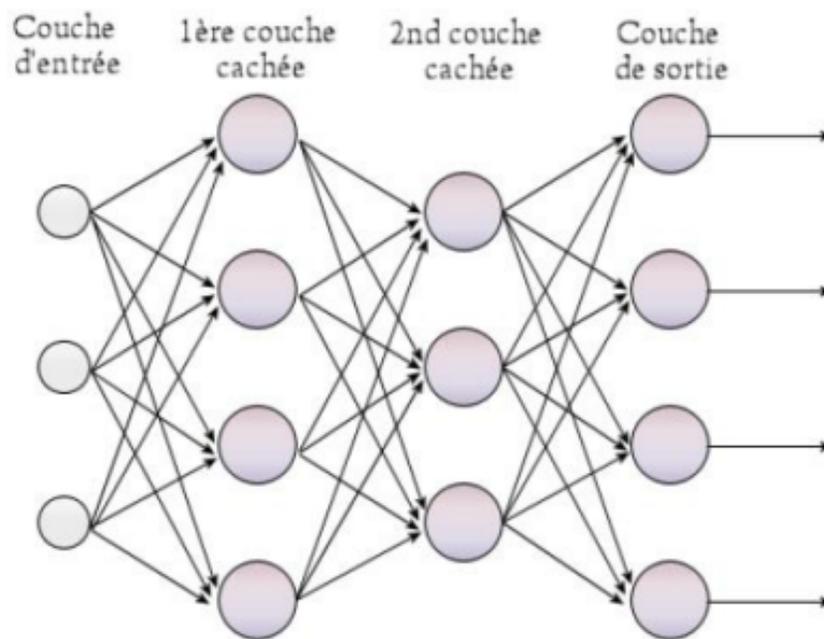


FIGURE 1.5 – Réseau de neurones multicouches [42]

1.4.3 Réseaux de Neurones Convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) ont été introduits par Lecun et al. La particularité des CNN est l'utilisation de l'opération de convolution dans les premières couches intermédiaires du réseau de neurones. À l'origine, cette opération est utilisée comme filtre dans le domaine de l'image ou du son afin de mettre en évidence des motifs ou réduire un type de bruits [52].

Une architecture CNN classique comprend généralement des couches alternées de convolution et de mise en commun, suivies d'une ou plusieurs couches entièrement connectées à la fin. Dans certains cas, une couche entièrement connectée est remplacée par une couche de mise en commun de la moyenne globale.

En plus des différentes fonctions de mappage, différentes unités de régulation telles que la normalisation et le dropout des lots sont également incorporées pour optimiser les performances du CNN. La disposition des composants du CNN joue un rôle fondamental dans la conception de nouvelles architectures et l'obtention de meilleures performances. Cette section aborde brièvement le rôle de ces composants dans une architecture CNN [64].

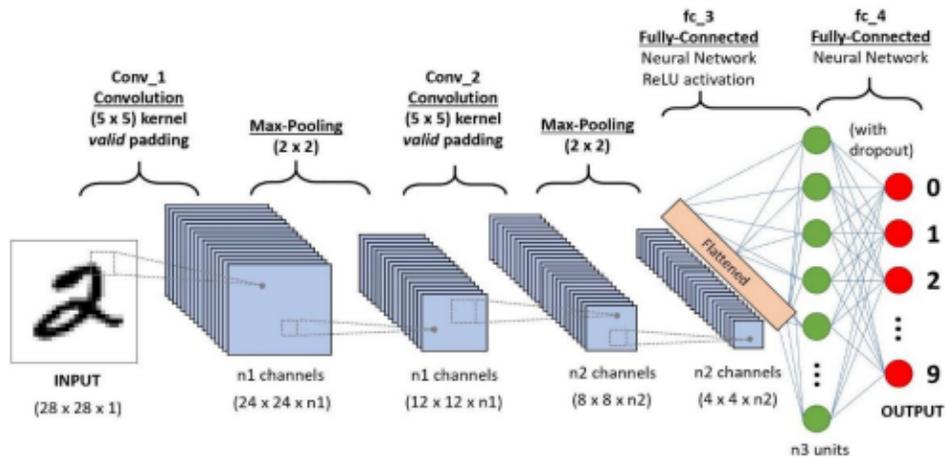


FIGURE 1.6 – architecture d'un réseau de neurone convolutif. [16]

La couche Convolution : La couche de convolution est parfois appelée couche d'extraction de caractéristiques.

Tout d'abord, une partie de l'image est connectée à la couche Convolution pour effectuer une opération de convolution qui consiste à calculer le produit scalaire entre le champ récepteur (région locale de l'image d'entrée ayant la même taille que celle du filtre) et le filtre. Le résultat de l'opération est un entier unique du volume de sortie. Ensuite, nous faisons glisser le filtre sur le champ récepteur suivant de la même image d'entrée et refaisons la même opération. Cette opération est répétée par le même processus encore et encore jusqu'à ce que toute l'image soit parcourue [29] (voir Figure 1.6).

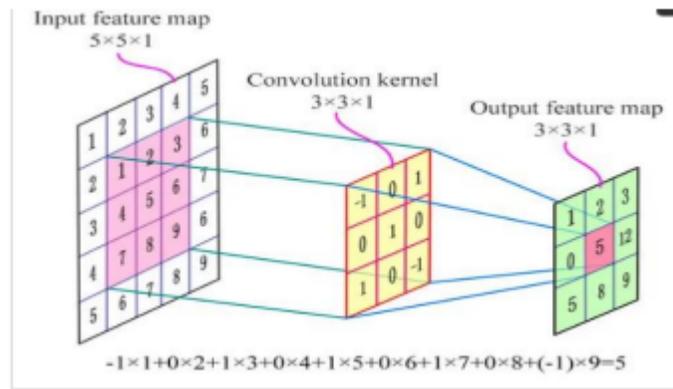


FIGURE 1.7 – La couche de convolution [29]

Couche de mise en commun (Pooling) : La couche de mise en commun (POOL) est une opération de sous-échantillonnage, généralement cette opération est appliquée entre deux couches de convolution. Sa fonction est de réduire progressivement la taille de la carte de fonctionnalités (matrice de convolution) pour réduire les paramètres et les calculs réseau, tout en conservant les informations importantes [44].

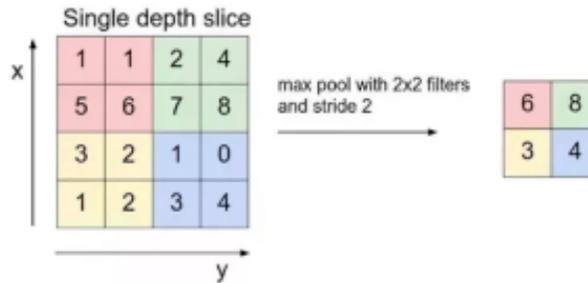


FIGURE 1.8 – La couche pooling [44]

Couche entièrement connecté (Fully Connected) Les couches totalement connectées font les mêmes tâches que celles des Réseaux de Neurones standards et tenteront de produire des notes de classe à partir des activations, pour les utiliser pour la classification. Il est également suggéré d'utiliser ReLu entre ces couches pour améliorer les performances [40].

Couche de sortie (output layer) : La couche de sortie, c'est la dernière couche de réseaux qui contient les neurones qui identifient les classes de modèle, donc le nombre de neurones à cette couche dépende du nombre de classes [45].

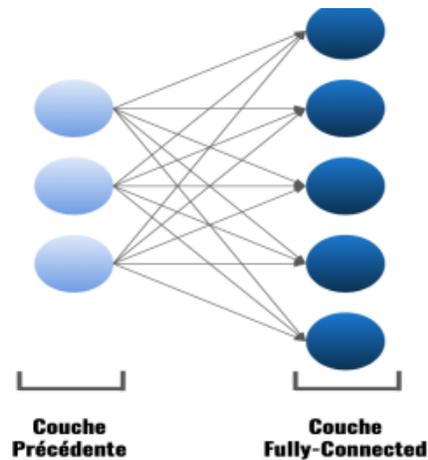


FIGURE 1.9 – Couche entièrement connecté (Fully Connected) [8]

1.4.4 Réseaux Antagonistes Génératifs (RAGs)

De nos jours, l’architecture des réseaux antagonistes génératifs (Generative adversarial networks ou GANs en anglais) décrite par Goodfellow et al[50] en 2014, est considérée comme la technologie la plus prometteuse en cours de développement dans le domaine de l’IA.

Ces réseaux antagonistes génératifs, sont une approche de la modélisation générative utilisant des méthodes d’apprentissage profond, telles que les réseaux de neurones convolutifs.

La modélisation générative est une tâche d’apprentissage non supervisée dans l’apprentissage automatique, qui implique la découverte et l’apprentissage automatiques des régularités ou des modèles dans les données d’entrée de manière à ce que le modèle puisse être utilisé pour générer ou produire de nouveaux exemples qui auraient pu être tirés de l’ensemble de données d’origine.

Les GANs sont un moyen astucieux d’entraîner un modèle génératif en présentant le problème comme un problème d’apprentissage supervisé avec deux sous-modèles : le modèle générateur que nous entraînons pour générer de nouveaux exemples, et le modèle discriminateur qui tente de classer les exemples comme vrais (du domaine) ou faux (générés)[31].

1.4.4.1 Définition

Les GANs sont essentiellement constitués d’un système de deux modèles de réseaux neuronaux concurrents qui se font concurrence et sont capables d’analyser, de capturer et de copier les variations au sein d’un ensemble de données. Ces deux réseaux sont placés en compétition dans un scénario de jeu à somme nulle. Les deux réseaux neuronaux qui composent un GAN sont appelés générateur et discriminateur. Le générateur est un type de réseau neuronal convolutif qui crée de nouvelles instances d’un objet. Le discriminateur est un type de réseau neuronal déconvolutif qui détermine l’authenticité de cet objet ou son appartenance à un jeu de données[85].

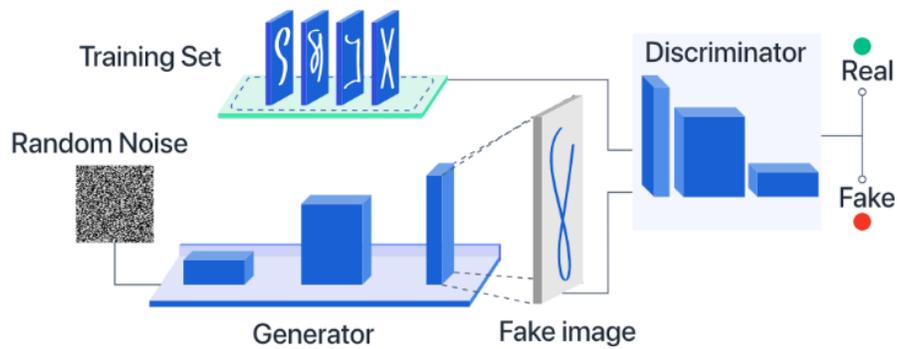


FIGURE 1.10 – Réseaux Antagonistes Génératifs [15].

1.4.4.2 Architecture et fonctionnement du GAN

L'architecture du modèle GAN implique deux sous-modèles, un générateur et un discriminateur [68]. Le générateur et le discriminateur sont tous deux des réseaux de neurones et ils fonctionnent tous les deux en compétition l'un avec l'autre pendant la phase d'entraînement. Les étapes sont répétées plusieurs fois et en cela, le générateur et le discriminateur s'améliorent de plus en plus dans leurs tâches respectives après chaque répétition.

- Le modèle génératif capture la distribution des données et est entraîné de manière à maximiser la probabilité que le discriminateur fasse une erreur.

- Le discriminateur, quant à lui, est basé sur un modèle qui estime la probabilité que l'échantillon qu'il a obtenu soit reçu à partir des données d'apprentissage et non du générateur.

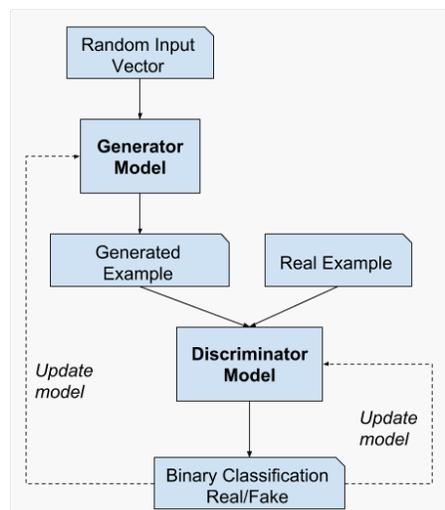


FIGURE 1.11 – Exemple d'architecture de modèle de réseau antagoniste génératif [12]

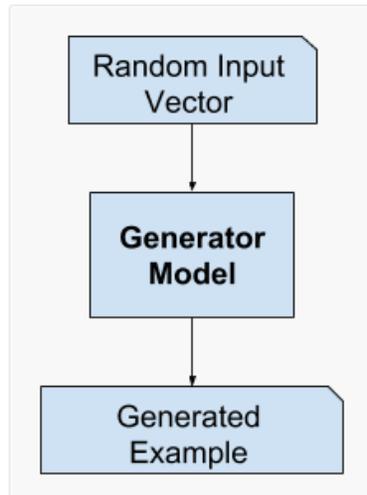


FIGURE 1.12 – Exemple de modèle de générateur GAN. [12]

1.4.4.2.2 Modèle du discriminateur : Modèle utilisé pour classer les exemples obtenus par le générateur comme vrais (du domaine) ou faux (générés)

Le modèle discriminateur prend un exemple du domaine comme entrée (réelle ou générée) et prédit une étiquette de classe binaire de réel ou faux (généré).

L'exemple réel provient de l'ensemble de données d'apprentissage. Les exemples générés sont générés par le modèle de générateur.

Le discriminateur est un modèle de classification normal .

Après le processus d'apprentissage, le discriminateur est écarté et on passe à l'entraînement du générateur[88] .

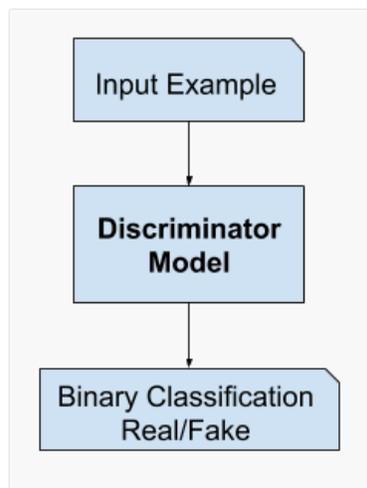


FIGURE 1.13 – Exemple de modèle du Discriminateur GAN. [12]

1.4.4.3 Différents types de GANs

En leur essence, les GANs sont constitués de deux réseaux de neurones artificiels, qui permettent de modéliser, imiter et générer n'importe quelle distribution de données avec un fort degré de réalisme. Dans cette section, nous présentons les différents types de GANs, et nous expliquons les types appliqués dans les applications médicales comme le DCGAN, CGAN, Pix2pix GAN, Cycle GAN, et ACGAN [11].

Cycle-GAN

Cycle GAN [124] est une technique qui utilise la propriété de cohérence du cycle pour former des modèles de traduction d'images non supervisés avec des images non appariées. Il traduit l'image d'entrée originale en une autre image fautive, puis l'image fautive est reconvertie en image d'entrée originale. Les générateurs avant et arrière sont nommés B et F respectivement dans la Figure (1.13).

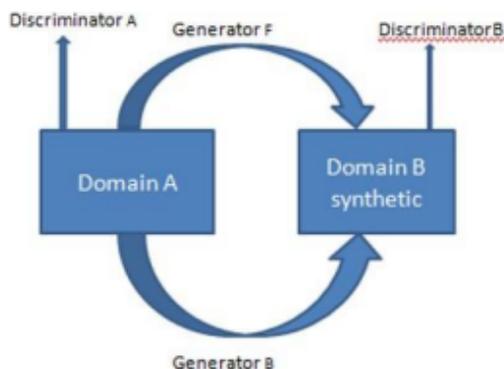


FIGURE 1.14 – Architecture de CycleGAN [99]

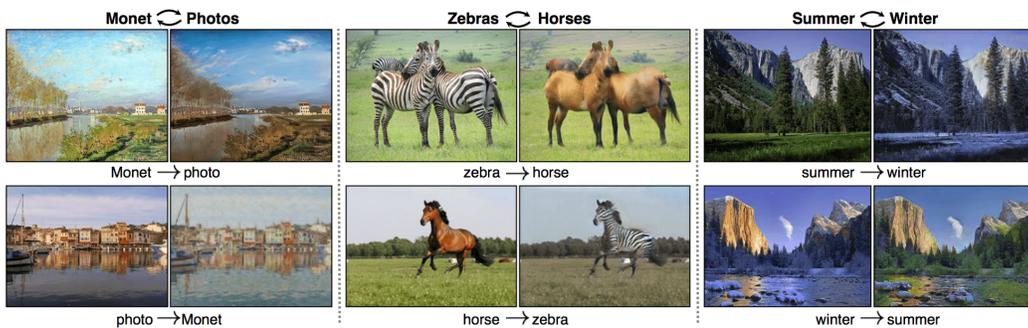


FIGURE 1.15 – Exemple de traduction d'image à image non appariée à l'aide de Cycle GAN[14]

DCGAN

Réseaux Antagonistes génératifs avec réseau de neurones convolutifs profonds [84] est l'extension du GAN introduit en premier. DCGAN peut maintenir la stabilité dans le processus d'apprentissage et créer des images de haute résolution. Le DCGAN utilise des réseaux neuronaux convolutifs avec une phase d'apprentissage et une phase de génération pour générer des images synthétiques. Pendant le processus d'apprentissage, un bruit aléatoire est donné comme entrée au générateur et le générateur avec le réseau neuronal multi déconvolutionnel produit des images ressemblant aux images réelles. Le discriminateur essaie de différencier les images générées de l'ensemble des images d'entraînement [84].

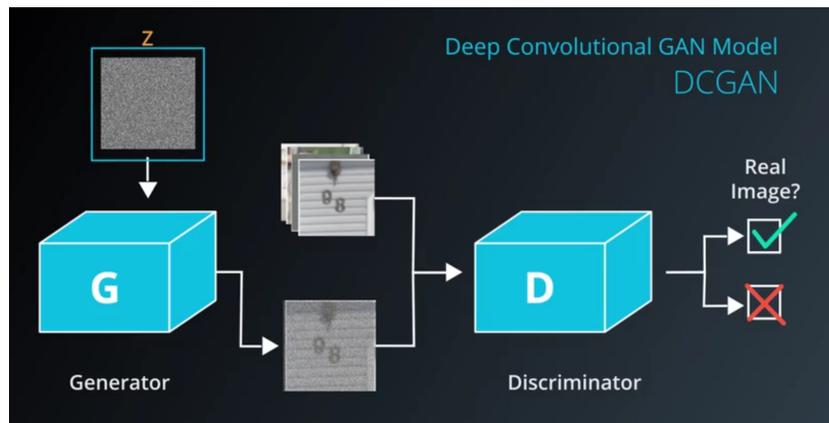


FIGURE 1.16 – Architecture de DCGAN [13]



FIGURE 1.17 – Exemple d'images générées par DCGAN [13]

CGAN [82]

c-GAN est un GAN avec certains paramètres conditionnels. C'est un GAN d'origine avec des informations préalables sous la forme d'une étiquette de classe. Dans c-GAN, un paramètre supplémentaire $\langle y \rangle$ est ajouté au générateur pour générer les données correspondantes. Des étiquettes sont également placées dans l'entrée du discriminateur afin que le discriminateur aide à distinguer les vraies données des fausses données générées. .

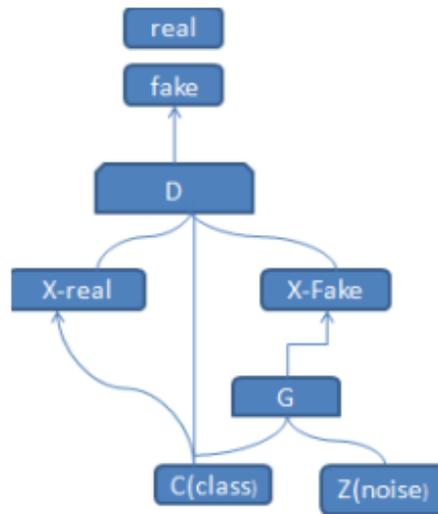


FIGURE 1.18 – Architecture de CGAN[99]

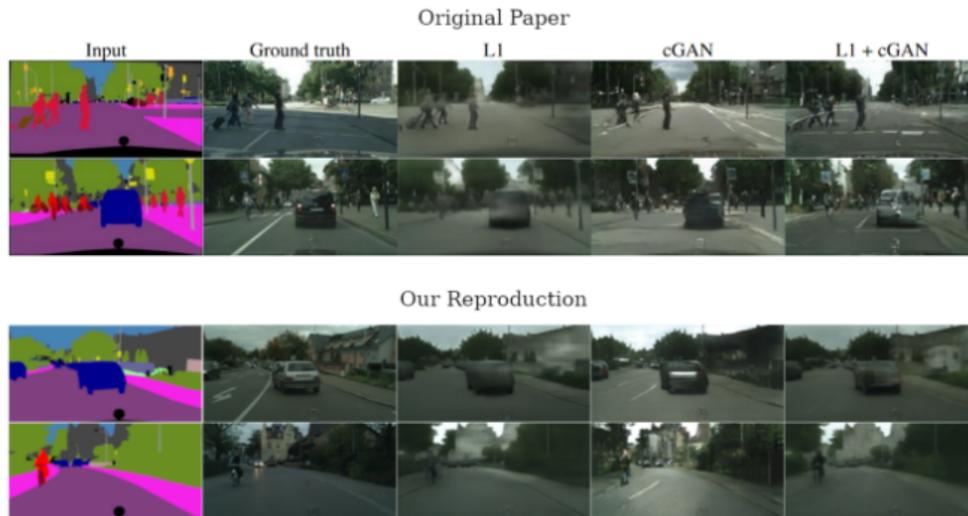


FIGURE 1.19 – Exemple d'utilisation de CGAN[61]

Pix2pix GAN :

Pix2Pix est un modèle de réseau adversarial génératif, ou GAN, conçu pour la traduction d'image à image à usage général. Le GAN Pix2Pix a été utilisé pour la conversion de cartes en photographies satellites, de photographies en noir et blanc en couleurs et de croquis de produits en photographies de produits. Dans Pix2Pix, le générateur est un réseau convolutif avec une architecture U-net, et le discriminateur est de type patchGAN [61].

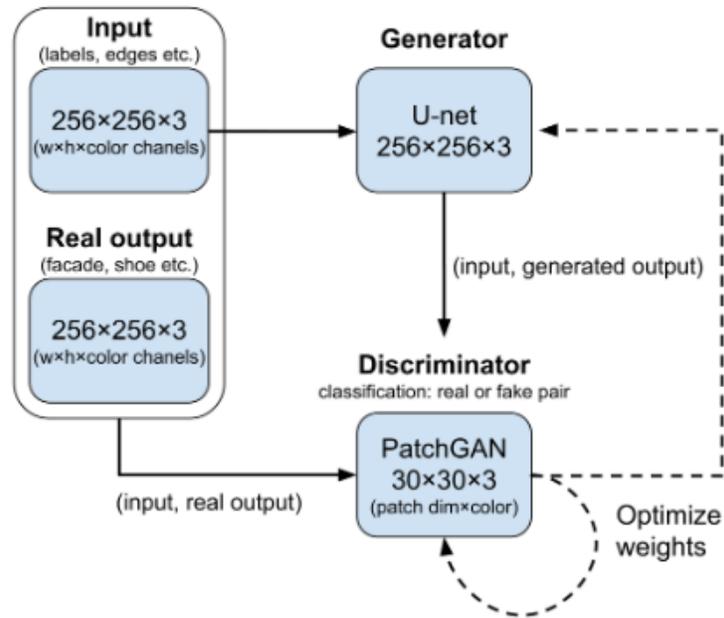


FIGURE 1.20 – Architecture de Pix2pix GAN[4]

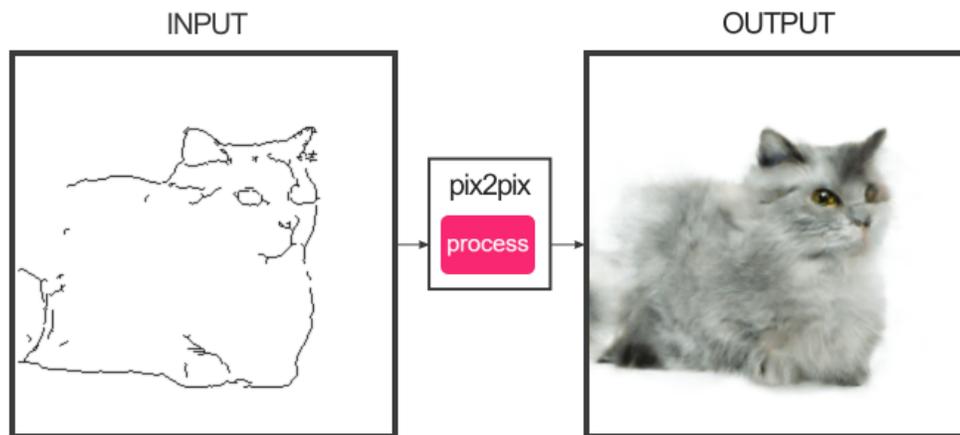


FIGURE 1.21 – Exemple d'utilisation de Pix2pix GAN[4]

Modèle de générateur U-Net :

Le modèle générateur U-Net prend une image comme entrée, contrairement au modèle GAN traditionnel, qui prend un point de l'espace latent comme entrée [61].

L'architecture du modèle U-Net est très similaire à l'architecture encodeur-décodeur car elle implique un sous-échantillonnage jusqu'à un goulot d'étranglement et un suréchantillonnage à nouveau jusqu'à obtention d'une image de sortie. [61].

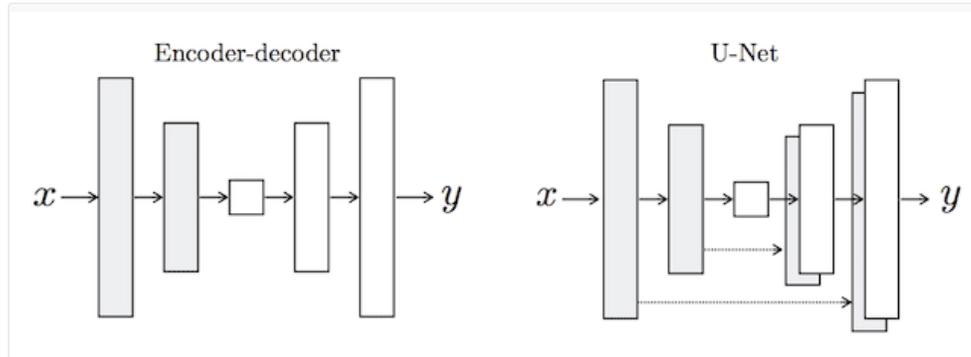


FIGURE 1.22 – Représentation des modèles Encodeur-Décodeur Générateur et U-Net Générateur[4]

Modèle de discriminateur PatchGAN :

Le modèle discriminateur prend une image du domaine source et une image du domaine cible et prédit la probabilité que l'image du domaine cible soit une version réelle ou générée de l'image source.

Contrairement au modèle GAN traditionnel qui utilise un réseau neuronal convolutif profond pour classer les images, le modèle Pix2Pix utilise un PatchGAN. Il s'agit d'un réseau neuronal convolutif profond conçu pour classer les patches d'une image d'entrée comme vrais ou faux, plutôt que l'image entière.

Le modèle du discriminateur PatchGAN est implémenté comme un réseau neuronal convolutif profond, mais le nombre de couches est configuré de telle sorte que le champ réceptif effectif de chaque sortie du réseau correspond à une taille spécifique dans l'image d'entrée. La sortie du réseau est une carte d'entité unique de prédictions réelles / fausses qui peuvent être moyennées pour donner un score unique.

ACGAN

Le classificateur auxiliaire GAN donne des résultats parfaits avec le jeu de données limité. Dans ce réseau, les informations secondaires sont reconstruites par le discriminateur. Ici, le modèle discriminateur peut s'adapter à l'identification multiclass et donne la distribution de probabilité des sources et des étiquettes de classe. Les échantillons dans le générateur ont les étiquettes de classe correspondantes.

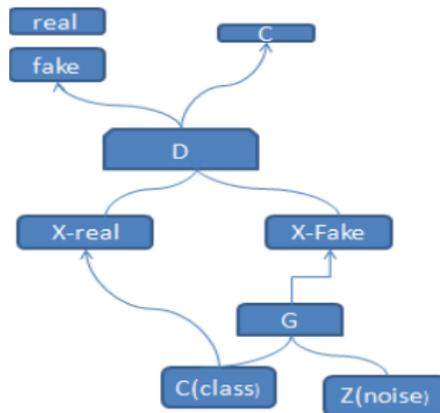


FIGURE 1.23 – Architecture de ACGAN [99]

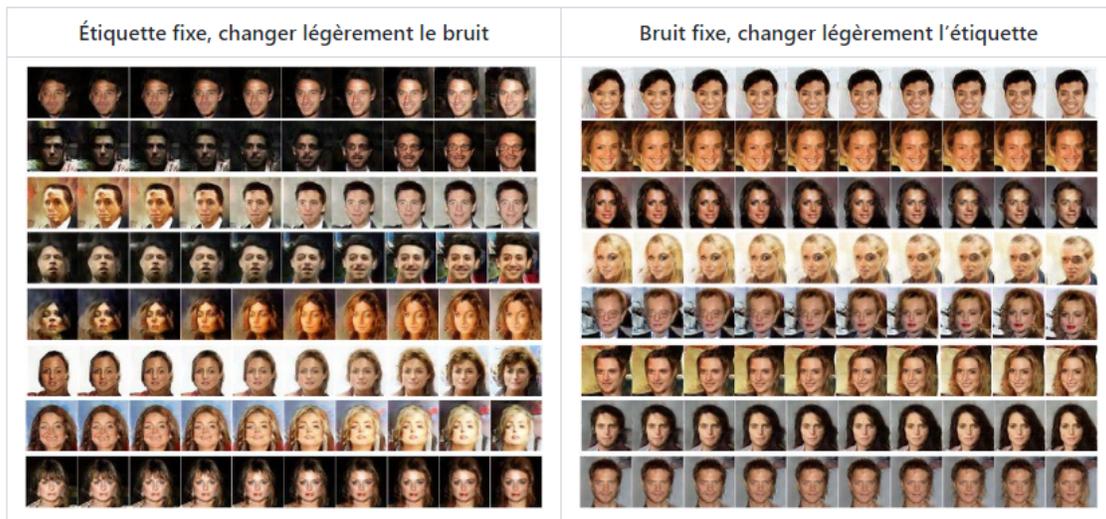


FIGURE 1.24 – Exemple d'images générées par ACGAN [13]

1.4.4.4 Domaines d'applications du GAN

Si le GAN s'est d'abord fait remarquer pour son aptitude à la falsification, son champ d'application est bien plus large. Cette architecture d'IA générative peut s'appliquer à des types de données très divers et ses applications potentielles sont nombreuses [9] [24] :

- **Génération d'images** : Les GANs peuvent générer de nouvelles images réalistes sur la base d'images réelles contenues dans un jeu d'entraînement, ces nouvelles images pourraient être utilisées pour des campagnes de marketing, la génération de logo, le divertissement, les réseaux sociaux, etc..



FIGURE 1.25 – Exemple d'images générées par le GAN [5]

- **Synthèse texte-image** : Il est possible de générer des images sur la base de descriptions textuelles. Cela pourrait aider l'industrie du film, à générer des images de séquences à tourner sur la base du script.

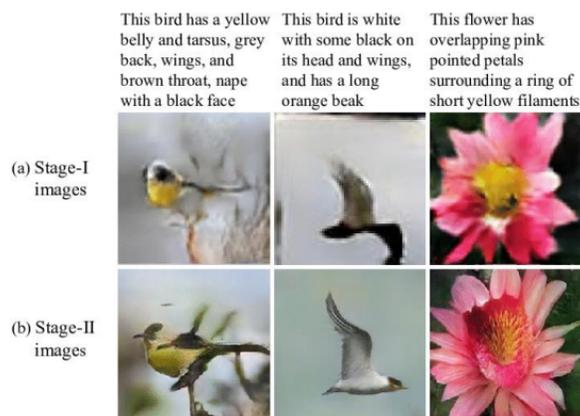


FIGURE 1.26 – Exemple textes en images [5]

- (a) Images en basse définition générées à partir du texte.
- (b) Images en haute définition générées à partir des images de l'étape 1.

- **Vieillessement du visage** : Cela pourrait être utile dans le domaine du divertissement et dans le domaine de la sécurité. Par exemple, l'identification faciale pourrait prendre en compte le vieillissement des personnes.

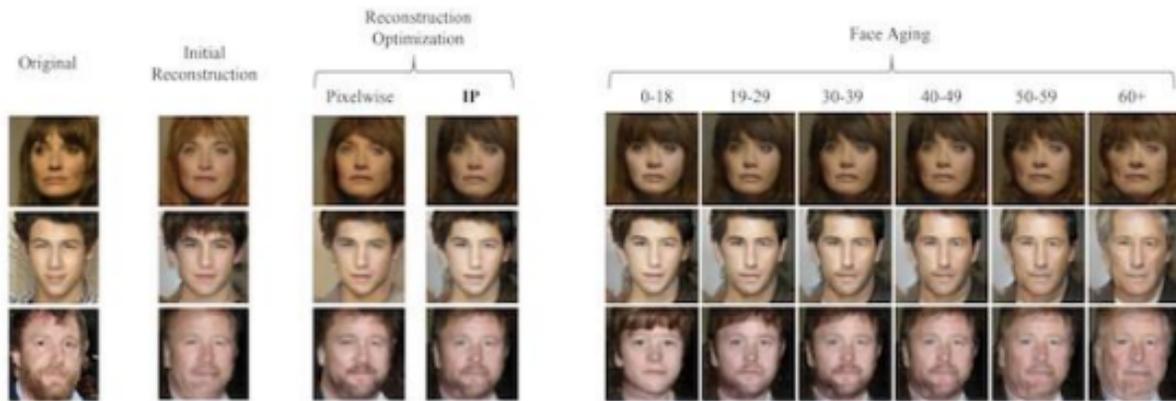


FIGURE 1.27 – Exemple de Vieillessement du visage [5]

- **Traduction d'image vers image** : Des images prises de jour peuvent être converties en images prises de nuit, des peintures pourraient être converties avec le style de Picasso ou de Van Gogh, des photos aériennes en images satellites, des dessins faits à la main en images réalistes, etc.



FIGURE 1.28 – Exemple image vers image [5]

● **Synthèse vidéo** : Les GANs peuvent être utilisés pour générer du contenu vidéo, ce qui prendrait moins de temps que si le contenu devait être créé manuellement. Cela pourrait aider à améliorer la productivité des créateurs de film, ou faciliter l'accès aux amateurs pour créer leurs propres vidéos.

● **Génération d'image en haute résolution** : Les photos de mauvaises qualités pourraient être améliorées sans perdre les détails essentiels.

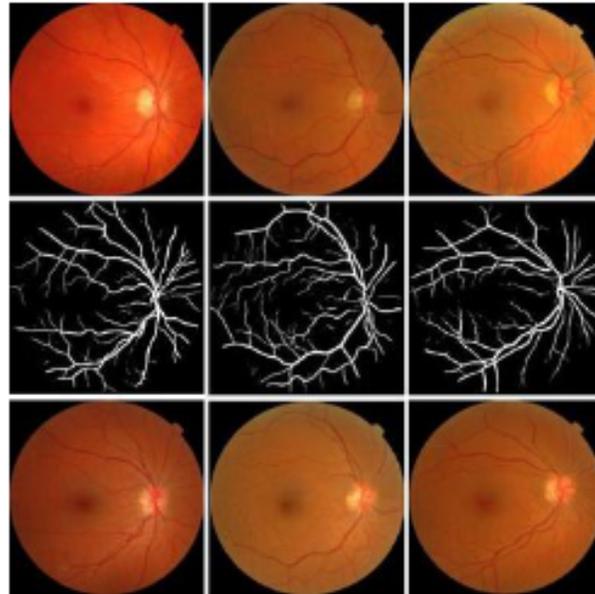


FIGURE 1.29 – Exemple de génération d'image haute résolution [5]

● **Compléter des parties manquantes d'images** :

Les GANs peuvent aider à régénérer les parties manquantes d'images.

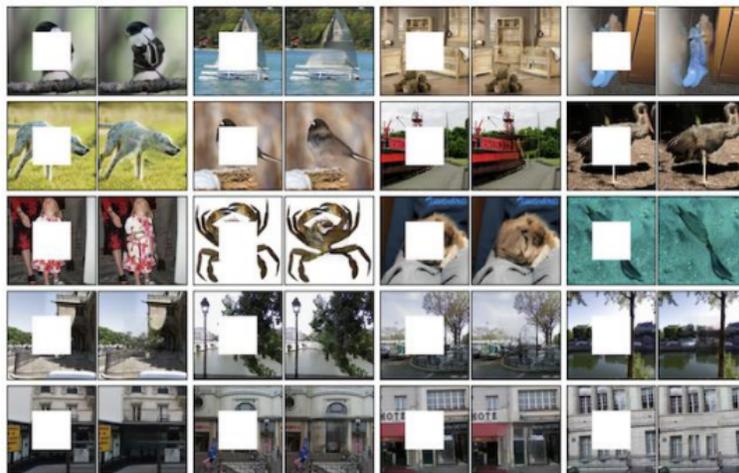


FIGURE 1.30 – Exemple Parties manquantes complétées [5]

1.4.4.5 Avantages et inconvénients

Les GANs présentent plusieurs avantages et inconvénients dont nous citons les plus importants ci-dessous :

Avantages :

- Apprentissage par rétropropagation,
- Capacité à synthétiser des images à des niveaux de réalisme sans précédent,
- Permet l'élaboration de modèles plus performants, avec un taux d'erreur fortement réduit.

Inconvénients :

- Non-convergence : les paramètres oscillent fortement sans se stabiliser,
- Mode collapse : le générateur produit des observations avec très peu de variété,
- Difficulté d'entraînement.

1.4.5 Fonctions d'activation

La fonction d'activation décide si un neurone doit être activé ou non en calculant la somme pondérée et en ajoutant un biais. Le but de la fonction d'activation est d'introduire une non-linéarité dans la sortie d'un neurone [2].

Pourquoi avons-nous besoin de fonctions d'activation non linéaires :

Un réseau de neurones sans fonction d'activation n'est essentiellement qu'un modèle de régression linéaire. La fonction d'activation effectue la transformation non linéaire de l'entrée, ce qui la rend capable d'apprendre et d'effectuer des tâches plus complexes [2].

1. Fonction sigmoïde :

C'est une fonction qui est tracée sous forme de graphique en forme de 'S' .

Équation : $A = 1/(1 + e^{-x})$

Nature : Non linéaire. Notez que les valeurs X se situent entre -2 et 2, les valeurs Y sont très raides. Cela signifie que de petits changements dans x entraîneraient également de grands changements dans la valeur de Y.

Plage de valeurs : 0 à 1

Utilisations : généralement utilisé dans la couche de sortie d'une classification binaire, où le résultat est 0 ou 1, car la valeur de la fonction sigmoïde se situe entre 0 et 1 uniquement. Ainsi, le résultat peut être facilement prédit comme étant 1 si la valeur est supérieure à 0,5 et 0 sinon .

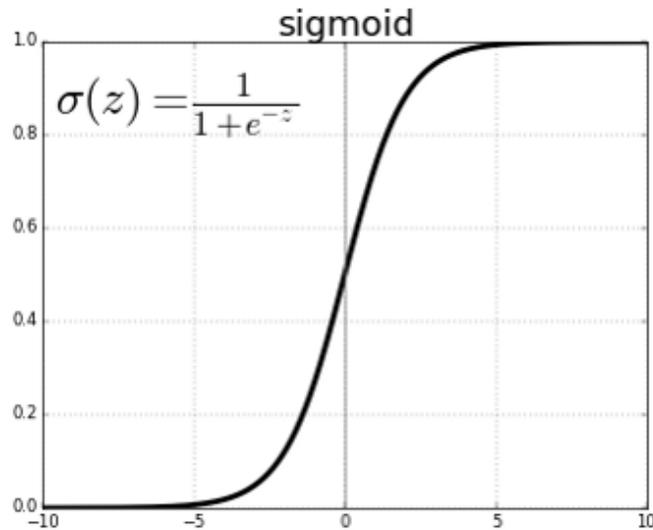


FIGURE 1.31 – Fonction d’activation sigmoïde [3]

2. **RELU :**

Signifie Unité linéaire rectifiée . C’est la fonction d’activation la plus utilisée. Principalement mis en œuvre dans les couches cachées du réseau neuronal.

Équation : $A(x) = \max(0, x)$. Il donne une sortie x si x est positif et 0 sinon.

Plage de valeurs : $[0, \infty]$

Nature : non linéaire, ce qui signifie que nous pouvons facilement rétropropager les erreurs et que plusieurs couches de neurones sont activées par la fonction ReLU.

Utilisations : ReLU est moins coûteux en calcul que sigmoïde car il implique des opérations mathématiques plus simples. À la fois, seuls quelques neurones sont activés, ce qui rend le réseau clairsemé, ce qui le rend efficace et facile à calculer.

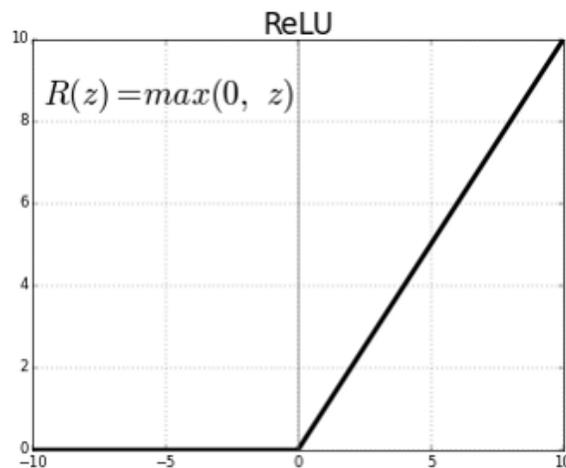


FIGURE 1.32 – Fonction d’activation ReLU [3]

En termes simples, ReLU apprend beaucoup plus rapidement que la fonction sigmoïde, mais le problème que nous voyons dans ReLU est le problème **Dying ReLU** où certains neurones ReLU meurent essentiellement pour toutes les entrées et restent inactifs quelle que soit l'entrée fournie, ici aucun gradient ne s'écoule et s'il y a un grand nombre de neurones morts dans un réseau neuronal, la performance est affectée, cela peut être corrigé en utilisant ce que l'on appelle Leaky ReLU où la pente est modifiée à gauche de $x = 0$ dans la Figure () et provoquant ainsi une fuite et étendant la plage de ReLU.

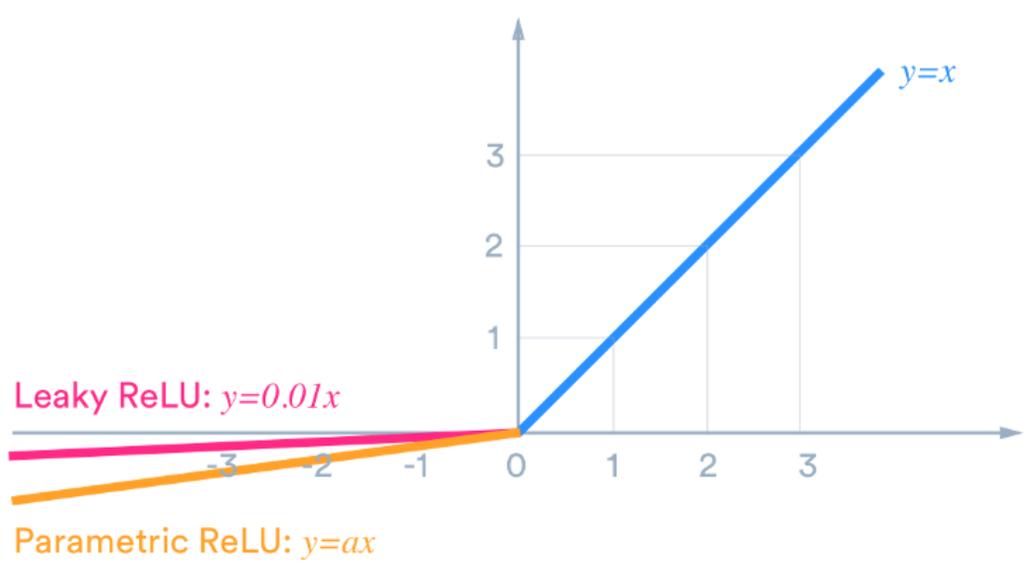


FIGURE 1.33 – Fonctions d’activations Leaky ReLU et Parametric ReLU [3]

3. Fonction Softmax :

La fonction softmax est également un type de fonction sigmoïde mais est pratique lorsque nous essayons de gérer des problèmes de classification, Softmax est utilisé pour la multi-classification tandis que Sigmoid est utilisé pour la classification binaire, la somme des probabilités est de Un pour Softmax [3].

Nature : non linéaire

Utilisations : Habituellement utilisé lorsque vous essayez de gérer plusieurs classes. La fonction softmax comprimerait les sorties de chaque classe entre 0 et 1 et diviserait également par la somme des sorties.

Sortie : La fonction softmax est idéalement utilisée dans la couche de sortie du classificateur où nous essayons en fait d’atteindre les probabilités pour définir la classe de chaque entrée.

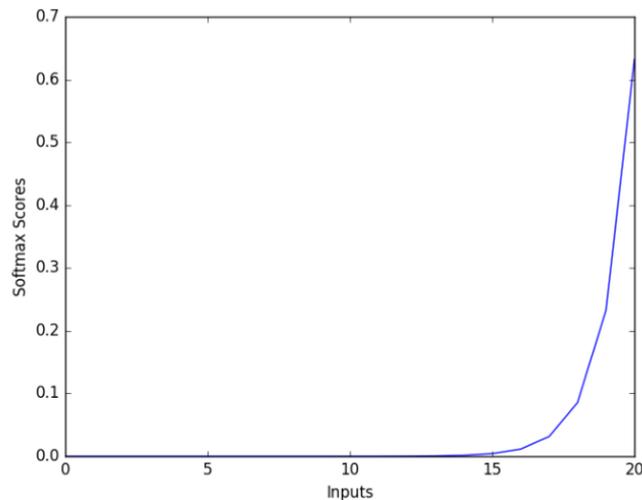


FIGURE 1.34 – Fonctions d’activations Softmax [3]

1.4.6 Fonction de perte

Une fonction de perte, ou Loss function, est une fonction qui évalue l’écart entre les prédictions réalisées par le réseau de neurones et les valeurs réelles des observations utilisées pendant l’apprentissage. Plus le résultat de cette fonction est minimisé, plus le réseau de neurones est performant.

1.4.7 Propagation arrière

Dans un réseau de neurones à propagation arrière, l’algorithme d’apprentissage a deux phases :

Un ensemble d’entrées d’entraînement est présenté au niveau d’entrée. Le réseau propage ces entrées niveau par niveau jusqu’à ce qu’une (ou des) sortie soit générée[67].

Si la sortie est différente de la sortie voulue, une erreur est calculée et puis propagée dans le réseau de la sortie vers l’entrée.

Les poids sont ajustés au fur et à mesure que l’erreur se propage .

1.5 Conclusion

Dans ce chapitre, nous avons effectué un aperçu sur l’apprentissage automatique et plus particulièrement les réseaux de neurones . Nous avons ensuite parlé du perceptron ainsi que des réseaux de neurones convolutifs. Nous avons terminé par la présentation d’une architecture de réseaux de neurones particulière à savoir le GAN, ainsi que son utilité, ses avantages et ses inconvénients.

Dans le chapitre qui suit, nous allons voir comment les GANs sont exploités pour le traitement des images médicales et plus particulièrement des images ophtalmologiques.

Utilisation des GANs pour le traitement des images ophtalmologiques

2.1 Introduction

Le succès de l'intelligence artificielle en médecine repose sur le besoin de grandes quantités de données d'entraînement de haute qualité. Cependant, le partage des données d'images médicales est souvent limité par des lois telles que la confidentialité médecin-patient. Bien qu'il existe des ensembles de données médicales accessibles au public, leur qualité et leur quantité sont souvent faibles. De plus, les ensembles de données sont souvent déséquilibrés et ne représentent qu'une fraction des images générées dans les hôpitaux ou les cliniques et ne peuvent donc généralement être utilisés que comme données d'entraînement pour des problèmes spécifiques.

Les progrès récents dans les techniques d'apprentissage profond ont conduit à une amélioration des capacités de diagnostic en ophtalmologie.

Les réseaux antagonistes génératif (GAN) ont démontré des performances remarquables dans la synthèse d'images et la traduction d'image à image. L'adoption du GAN pour l'imagerie médicale augmente pour la génération et la traduction d'images, mais il n'est pas familier aux chercheurs dans le domaine de l'ophtalmologie.

Dans ce chapitre, nous présentons une revue de la littérature sur l'application du GAN dans les domaines d'image en ophtalmologie afin de discuter des contributions importantes et d'identifier les orientations de recherche futures potentielles.

2.2 Utilité des GANs dans le domaine médical

Les réseaux antagonistes génératifs (GAN) et leurs extensions ont ouvert de nombreuses voies intéressantes pour résoudre des problèmes bien connus et complexes d'analyse d'images médicales, tels que le débruitage, la super-résolution, la reconstruction, la segmentation, la simulation, la détection, voire même la classification de données. De plus, leur capacité à synthétiser des images de taille à des niveaux de réalisme sans précédent donne également l'espoir que la rareté chronique des données étiquetées dans le domaine médical puisse être résolue à l'aide de ces modèles génératifs.

2.2.1 Segmentation

La segmentation d'image est une tâche dans laquelle les pixels ou les zones d'une image se voient attribuer une étiquette de catégorie. La segmentation est la plus fréquemment étudiée pour l'identification de structures telles que les vaisseaux rétiniens[107], les couches rétinienne et le nerf optique[123]. L'identification des zones pathologiques sur les images oculaires peut aider les cliniciens à faire un diagnostic plus précis[60][97].

Pour améliorer les performances de segmentation, certaines études ont utilisé le GAN basé sur des patches [89], des couches de mise en commun multi-noyaux [87][57], des modèles topologiques à structure contrainte [106], de grands champs réceptifs [118] et des générateurs d'équilibre symétrique avec mécanismes d'attention [122].

Des GANs conditionnels [102][63] ont été utilisés pour détecter les maladies cornéennes[109]. La segmentation du disque optique permet d'évaluer les lésions du nerf optique et le Glaucome[28].

Le Tableau (2.1) représente un résumé de la revue de la littérature pour la tâche de segmentation à l'aide du GAN [115] :

Publication	Technique de base	Domaine	Cible	Résumé
Iqbal et coll. [60]	GAN conditionnel	Photographie du fond d'œil	Vaisseaux rétiens	Le cadre a permis la segmentation de l'image des vaisseaux rétiens à partir d'un petit ensemble d'entraînement
Wang et coll. [102]	GAN conditionnel (à l'aide de PatchGAN)	Photographie du fond d'œil	Disque optique et coupe optique	Adaptation de domaine non supervisée pour la segmentation conjointe du disque optique et de la tasse à l'aide d'un discriminateur basé sur un patch
Son et coll. [97]	GAN conditionnel (en utilisant U-Net comme générateur)	Photographie du fond d'œil	Vaisseaux rétiens	Le modèle GAN a segmenté la vascularisation rétinienne et le disque optique à l'aide d'un ensemble de données, qui consistait en des images fundoscopiques et une segmentation manuelle des vaisseaux
Rammy et coll. [89]	GAN conditionnel	Photographie du fond d'œil	Vaisseaux rétiens	GAN basé sur un patch avec fonction de perte supplémentaire pour apprendre les vaisseaux rétiens segmentés en vaisseaux minces et épais avec des performances améliorées
Park et coll. [87]	GAN conditionnel	Photographie du fond d'œil	Vaisseaux rétiens	Le modèle GAN proposé avec une mise en commun multi-noyaux et une perte de faux négatifs pourrait segmenter les vaisseaux sanguins rétiens de manière plus robuste
Heiser et coll. [57]	Pix2Pix (GAN conditionnel)	OCT rétinien périrapillaire	Couche de fibres nerveuses, membrane de Bruch, frontière choroïde-sclérotique	L'utilisation d'un réseau antagoniste génératif et de données non étiquetées peut améliorer les performances de segmentation pour l'analyse morphométrique 3D des volumes de tête du nerf optique glaucomateux
Yang et coll. [104]	GAN conditionnel (structure topologique contrainte)	Photographie du fond d'œil	Vaisseaux rétiens	Le modèle GAN proposé à structure topologique limitée a identifié les artères et les veines rétiennes par segmentation à partir de l'arrière-plan complexe des images rétiennes
Yang et al. [107]	GAN conditionnel	Photographie du fond d'œil	Vaisseaux rétiens	Pour séparer les vaisseaux sanguins de l'image du fond d'œil, le modèle pourrait détecter plus de petits vaisseaux et localiser le bord des vaisseaux sanguins avec plus de précision.
Zhao et coll. [117]	GAN conditionnel (avec un grand champ réceptif)	Photographie du fond d'œil	Vaisseaux rétiens	L'algorithme de segmentation des vaisseaux rétiens proposé à l'aide de GAN avec un grand champ réceptif pourrait capturer des caractéristiques sémantiques de vaisseau à grande échelle de haut niveau
Kadambi et coll. [63]	Wasserstein GAN	Photographie du fond d'œil	Disque optique et coupe optique	L'adaptation de domaine basée sur WGAN a montré de meilleures performances que les modèles de base pour la segmentation conjointe du disque optique et de la tasse dans les images de fond d'œil
Bian et coll. [28]	GAN conditionnel (en utilisant U-Net comme générateur)	Photographie du fond d'œil	Disque optique et coupe optique	La méthode proposée a effectué avec succès la segmentation du disque optique et de la tasse. Le rapport tasse/disque a été calculé automatiquement avec une bonne performance
Khan et coll. [66]	GAN conditionnel	Images infrarouges méibographiques	Glande de Meibomius	Le GAN proposé a automatiquement identifié la zone des glandes de Meibomius et a surpassé les méthodes de pointe
Yildiz et coll. [109]	GAN conditionnel	Images de microscopie confocale cornéenne in vivo	Nerfs suboculaires	La segmentation automatique des nerfs suboculaires dans des images de microscopie confocale in vivo a été réalisée à l'aide des techniques U-Net et GAN comme outil de diagnostic des maladies de la cornée
Zhou et al. [122]	GAN conditionnel (en utilisant U-Net comme architecture de référence)	Photographie du fond d'œil	Vaisseaux rétiens	Le modèle GAN a renforcé la segmentation des vaisseaux rétiens dans le fond à faible contraste à l'aide d'un GAN d'équilibre symétrique (basé sur U-Net), de caractéristiques multi-échelles qui affinent les blocs et le mécanisme d'attention

Tableau 2.1-Résumé de la revue de la littérature pour la tâche de segmentation d'images utilisant gan dans les domaines d'imagerie ophtalmologique[115]

2.2.2 Augmentation de données

Le développement d'un modèle d'apprentissage automatique nécessite suffisamment de données [65]. Mais les bases de données d'images médicales souffrent d'un manque de données surtout dans le cas de certaines pathologie. De nombreux chercheurs ont montré que l'augmentation des données à l'aide de techniques GAN peut apporter un avantage supplémentaire par rapport aux méthodes traditionnelles [98]. Récemment, les techniques GAN ont été largement utilisées pour synthétiser des images médicales réalistes pour l'augmentation des données. Différents GANs ont été testés et utilisés pour l'augmentation des données. Nous retrouvons :

Le DcGAN utilisé pour générer des images synthétiques du fond d'œil périapillaire [43]. Le modèle d'apprentissage automatique basé sur DCGAN a montré une meilleure performance au diagnostic du glaucome que les modèles d'apprentissage profond conventionnels.

Le PGGAN testé par Burlina et al.[32] pour générer des images rétinienne réalistes. Dans leur étude, deux spécialistes de la rétine n'ont pas pu distinguer les images réelles des images synthétiques. Ainsi que Zheng et al.[121] qui l'ont exploité pour générer des images OCT rétinienne réalistes.

Le GAN conditionnel [69] a été également servi pour générer des images de fond d'œil à haute résolution basées sur des images de masques structurels et de lésions[122] ou pour amélioré les performances de segmentation des images OCT rétinienne [69].

Le CycleGAN a été appliqué à l'augmentation des données OCT pour les maladies rares de la rétine telles que le glaucome à angle fermé, la maladie conjonctivale [113] et les images de topographie cornéenne pour la détection du kératocône [23].

D'autres méthodes ont été utilisées pour l'augmentation des données de fond d'oeil comme le générateur multicanal, qui entraîne plusieurs modèles GANs ; un pour chaque caractéristique tels que les exsudats, les microanévrismes et les saignements [103]. Ainsi que la génération des images OCT synthétiques avec différents grades pathologiques en intégrant à la fois des données normales et pathologiques[56].

le Tableau (2.2) résume les études qui ont porté sur l'augmentation des données pour les domaines d'imagerie ophtalmologique à l'aide du GAN [115] :

Publication	Technique de base	Domaine	Résumé
Diaz-Pinto et coll. [43]	Le	Photographie du fond d'œil péripapillaire (photo du disque optique)	DCGAN a été en mesure de générer des images de disques optiques synthétiques de haute qualité
Burlina et coll. [32]	PgGAN	Photographie du fond d'œil	La technique GAN a été utilisée pour synthétiser des images de fond d'œil réalistes à haute résolution servant d'ensembles de données proxy à l'usage de spécialistes de la rétine et de modèles d'apprentissage profond.
Zheng et coll. [10]	PgGAN	OCT rétinien (domaine spectral)	La qualité d'image des images <i>réelles par rapport aux images OCT synthétiques</i> générées par gan était similaire: les images synthétiques de l'OCT ont pu servir d'augmentation des ensembles de données de formation pour les modèles d'apprentissage profond
Zhou et al. [12]	GAN conditionnel	Photographie du fond d'œil	Pour générer une grande quantité de données d'entraînement équilibrées, le modèle GAN a synthétisé des images de fond d'œil à haute résolution de la rétinopathie diabétique qui peuvent être manipulées avec des informations arbitraires sur le classement et les lésions.
Wang et coll. [103]	GAN multicanal (GAN vanille modifié)	Photographie du fond d'œil	Le modèle a généré une série d'images de fond d'œil correspondant aux caractéristiques de la rétinopathie diabétique en diffusion et a pleinement utilisé les données étiquetées et non étiquetées.
He et coll. [56]	Lissage d'étiquettes GAN (GAN vanille modifié)	OCT rétinien	Le modèle GAN a généré les images synthétiques non étiquetées à partir d'échantillons d'entraînement OCT limités, et le mélange des images synthétiques et des images réelles peut être utilisé comme données d'entraînement pour améliorer les performances de classification.
Yoo et coll. [112]	CycleGAN	OCT rétinien	Gan a généré des images OCT de maladies rares à partir d'images OCT normales et a augmenté la précision du diagnostic des maladies rétinienne rares avec une classification à quelques coups
Kugeliman et coll. [69]	GAN conditionnel	OCT rétinien (niveau du patch)	GAN a été possible pour générer des correctifs qui sont visuellement impossibles à distinguer de leurs variantes réelles et a amélioré les performances de segmentation
Zheng et coll. [119]	PgGAN	OCT du segment antérieur	Les images OCT synthétiques générées par gan semblaient être de bonne qualité, selon les spécialistes du glaucome, et le modèle d'apprentissage profond pour la détection de fermeture d'angle a été amélioré en utilisant des images synthétiques et réelles
Yoo et coll. [113]	CycleGAN, PGGAN	Image de surface oculaire	Pour améliorer la précision du diagnostic, le GAN a été adopté pour effectuer l'augmentation des données des images de surface oculaire avec mélanome conjonctival
Abdelmotaal et coll. [23]	Pix2pix	Topographie cornéenne (images de Scheimpflug)	Les images synthétisées ont montré une qualité plausible évaluée subjectivement et objectivement. L'entraînement à l'apprentissage profond avec une combinaison d'images réelles et synthétisées a montré de meilleures performances de classification pour détecter le kératocône

Tableau 2.2.-Résumé de la revue de la littérature pour la tâche d'augmentation des données à l'aide du GAN dans les domaines d'imagerie ophtalmologique [115]

2.2.3 Débruitage et super-résolution

Les tâches d'amélioration de l'image telles que le débruitage et la super-résolution sont importantes car les images ophtalmologiques souffrent généralement des limitations de l'appareil, de la compétence de l'examineur, des variations de l'anatomie oculaire et de la transparence de l'axe visuel. La qualité de l'image peut affecter les performances de diagnostic. C'est pourquoi, plusieurs chercheurs ont tenté de développer des modèles GANs pour l'élimination du bruit et l'augmentation de la résolution des images ophtalmologiques. L'image du fond d'œil comporte plusieurs artefacts et bruits, y compris la brume globale, la brume de bord, les arcs et les cils. Le GAN conditionnel a été le plus utilisé et les travaux varient selon le type de bruit traité tels que les mouchetures dans les images OCT rétiniennes [53], les artefacts d'ombre [36], les mouchetures dans l'OCT rétinien péripapillaire [35] et dans l'OCT du segment antérieur [86].

La super résolution consiste en la génération d'images de hautes résolution à partir d'images de faibles résolution. Ce problème a été traité simultanément que l'élimination du bruit, en utilisant soit le GAN conditionnel [58] soit le CycleGAN [41][110, 78]. Le CycleGAN permet de réduire efficacement les artefacts et fournir des images rétiniennes plus claires aux cliniciens.

Le PGGAN avec une modélisation conditionnelle a été appliquée pour le problème de super-résolution, aux images du fond d'œil [80]. Le PGGAN a été adapté pour obtenir des images de disques optiques synthétiques à haute résolution avec une mise à l'échelle 4 fois supérieure à l'aide de SRGAN [51].

Le Tableau (2.3) résume les études portant sur la débruitation ou la super-résolution pour les domaines d'imagerie ophtalmologique [115] :

Publication	Technique de base	Domaine	Cible	Résumé
Halupka et coll. [53]	GAN de Wasserstein modifié + perte perceptuelle (GAN conditionnel)	OCT rétinien (domaine spectral)	Suppression du bruit de moucheture	Le GAN a été utilisé pour réduire les artefacts de mouchetures dans les images OCT rétinienne. La méthode a amélioré les mesures de qualité d'image pour l'OPO
Mahapatra et coll. [80]	PGGAN avec une conception conditionnelle	Photographie du fond d'œil	Super-résolution	La super-résolution d'image utilisant le PGGAN à plusieurs étages surpasse les méthodes concurrentes et les GAN de base. Les images super-résolues peuvent être utilisées pour la détection de repères et de pathologies
Huang et coll. [58]	GAN conditionnel	OCT rétinien	Super-résolution et suppression du bruit	Le modèle GAN a efficacement supprimé le bruit de mouchetures et les images OCT super-résolues à différentes échelles
Ouyang et coll. [86]	GAN conditionnel	OCT du segment antérieur	Suppression du bruit de moucheture	Le modèle a supprimé les artefacts spéculaires indésirables et les motifs de bruit de mouchetures pour améliorer la visualisation des images OCT cornéennes et limbiques
Yoo et coll. [119]	CycleGAN	Photographie du fond d'œil	Suppression des artefacts et du bruit	Le modèle GAN a supprimé automatiquement les artefacts dans une photographie du fond d'œil sans faire correspondre les images appariées
Cheong et coll. [36]	DesDowGAN (GAN conditionnel modifié avec perte perceptuelle)	OCT rétinien péripapillaire (domaine spectral)	Suppression des artefacts d'ombre de navire	Le modèle GAN utilisant des images d'artefacts masquées manuellement et la fonction de perte perceptuelle a supprimé les artefacts d'ombre des vaisseaux sanguins des images OCT de la tête du nerf optique
Chen et coll. [35]	GAN conditionnel	OCT rétinien péripapillaire (domaine spectral)	Suppression du bruit de moucheture	Le modèle GAN a été conçu pour la réduction du bruit de moucheture dans les images OCT et a conservé les détails de texture trouvés dans OCT
Das et coll. [41]	CycleGAN	OCT rétinien	Super-résolution et suppression du bruit	Pour atteindre la débruitation et la super-résolution, l'apprentissage contradictoire avec cohérence de cycle a été utilisé sans nécessiter de paires alignées basse-haute résolution
Ha et coll. [51]	GAN à super-résolution améliorée (SRGAN)	Photographie du fond d'œil péripapillaire (photo du disque optique)	Super-résolution	L'approche GAN était capable d'augmenter 4 fois la mise à l'échelle et l'amélioration des détails anatomiques en utilisant l'amélioration du contraste, de la couleur et de la luminosité
Yuhao et coll. [78]	CycleGAN	Photographie du fond d'œil	Suppression des artefacts et du bruit	Le modèle développé a déhazé des images rétinienne cataractaires à l'aide d'images rétinienne claires non appariées et d'images de cataracte

Tableau 2.3- Résumé de la revue de la littérature pour les tâches d'amélioration d'image (débruitage et super-résolution) à l'aide du GAN dans les domaines de l'imagerie ophtalmologique [115]

2.2.4 Transfert de domaine

Les Gans ont la capacité de transformer un bruit en une image, donc ils permettent de passer d'un domaine à un autre domaine c'est ce qu'on appelle transfert de domaine.

Le transfert de domaine permettra de varier les types d'images et améliorer ainsi le diagnostic par obtention de nouvelles données cliniques sans examens supplémentaires[96]. Plusieurs études utilisant le GAN se sont principalement concentrées sur le transfert de domaine pour les domaines d'imagerie ophtalmologique. Le transfert de domaine a surtout été exploité pour l'augmentation des données en utilisant beaucoup plus le GAN Conditionnel. Nous pouvons citer :

- La génération d'images de synthèses réalistes du fond d'oeil à partir des images de vaisseaux masqués [38] ou d'images masquées du disque optique [116].
- La transformation des images OCT en images de synthèses auto-fluorescentes rétinienne [104].
- L'obtention d'images de synthèses réalistes d'angiographie rétinienne avec rétinopathie diabétique à partir d'images du fond d'oeil[100].
- La conversion des images OCT du domaine temporel en OCT du domaine spectral [71, 70].

Le cycleGAN a été aussi exploité dans ce type d'application pour transformer une image ultra large en image classique d'un fond d'oeil [114] et inversement [62].

Le Tableau (2.4) résume la revue de la littérature pour la tâche de transfert de domaine à l'aide du GAN dans les domaines d'imagerie ophtalmologique [115] :

Publication	Technique de base	Domaine	Résumé
Costa et coll. [38]	GAN conditionnel	Image du navire → photographie du fond d'œil	L'étude a proposé un cadre de traduction d'images de réseau de vaisseaux à rétinies produisant un arbre de vaisseaux simplifié et des images rétinienues réalistes en estimant l'espace latent. L'autoencodeur a été utilisé pour synthétiser de nouvelles images de vaisseaux rétinienues en dehors de l'entraînement du GAN
Zhao et coll. [118]	GAN conditionnel	Image du navire → photographie du fond d'œil	La synthèse d'images rétinienues peut être apprise efficacement de manière axée sur les données à partir d'un échantillon de taille relativement petite à l'aide d'une architecture GAN conditionnelle
Yu et coll. [119]	Pix2pix (avec générateur ResU-net) (GAN conditionnel)	Image du navire → photographie du fond d'œil	Pour agrandir les ensembles de données d'entraînement afin de faciliter l'analyse d'images médicales, le MCML (multiple-channels-multiple-landmarks) a été développé pour synthétiser des images de fond d'œil en couleur à partir d'une combinaison d'images masquées de vaisseaux et de disques optiques
Wu et coll. [104]	GAN conditionnel	Autofluorescence volumétrique de l'OCT → du fond d'œil rétinien	Les images OCT en face ont été synthétisées à partir de l'OCT rétinien volumétrique par projection de voxel sommée restreinte. Les images d'autofluorescence du fond d'œil ont été générées à partir d'images OCT en face à l'aide du GAN pour identifier la région d'atrophie géographique.
Tavakkoli et coll. [109]	GAN conditionnel	Photographie du fond d'œil → angiographie à la fluoresceïne	Le GAN proposé a produit des images d'angiographie à la fluoresceïne anatomiquement précises qui ne pouvaient pas être distinguées des angiographies réelles.
Yoo et coll. [114]	CycleGAN	Photographie de fond d'œil ultra-large → photographie de fond d'œil	Les images à ultra-champ ont été traduites avec succès en images traditionnelles de style photographie du fond d'œil par CycleGAN, et les principales informations structurelles de la rétine et du nerf optique ont été conservées.
Ju et coll. [62]	CycleGAN	Photographie de fond d'œil → photographie de fond d'œil ultra-large	Le modèle CycleGAN a transféré les photographies du fond d'œil en couleur vers des images ultra-larges afin d'introduire des données supplémentaires pour les images ultra-larges étendues existantes. La méthode proposée a été adoptée pour le classement de la rétinopathie diabétique et la détection des lésions
Lazaridis et al. [71, 70]	GAN de Wasserstein + perte perceptuelle (GAN conditionnelle)	OPO du domaine temporel → de l'OCT du domaine spectral	L'OCT du domaine temporel a été converti en OCT à domaine spectral synthétique à l'aide du GAN. Le modèle a amélioré la puissance statistique des mesures par rapport à celles dérivées de l'OCT d'origine

Tableau (2.4)-Résumé de la revue de la littérature pour la tâche de transfert de domaine à l'aide du GAN dans les domaines d'imagerie ophtalmologique [115]

2.2.5 Prédiction post-intervention

L’objectif de la prédiction post-intervention est de générer une image qui explique comment l’apparence anatomique change après le traitement. Cette tâche est utile aux cliniciens et aux patients pour comprendre comment l’intervention affectera le pronostic des maladies. Cependant, les études incluses présentent plusieurs limites en termes de périodes de suivi à court terme pour la prédiction et l’interventions non normalisées [76].

Yoo et al.[111] ont proposé un modèle de prédiction de l’apparence postopératoire pour la chirurgie de décompression orbitaire pour l’ophtalmopathie thyroïdienne en utilisant un GAN conditionnel . Liu et al. [77] ont montré que le modèle Pix2pix pouvait générer un OCT post-injection synthétique en utilisant des images pré-injection pour estimer la réponse à court terme . Lee et al.[74] ont conçu un GAN conditionnel avec une entrée multicanal pour l’injection anti-VEGF qui est un traitement pour la dégénérescence maculaire .

Le Tableau (2.5) présente les études qui ont porté sur les taches de prédiction post-intervention à l’aide du GAN [115] :

Publication	Technique de base	Domaine	Intervention	Résumé
Yoo et coll. [111]	GAN conditionnel, CycleGAN	Images faciales périorbitaires	Chirurgie de décompression orbitaire	Le modèle développé a transformé les images d’entrée faciale préopératoires en images postopératoires prédites pour la décompression orbitaire pour l’ophtalmopathie associée à la thyroïde.
Liu et coll. [77]	Pix2pix (GAN conditionnel)	OCT rétinien	Injection intravitréenne de facteur de croissance endothélial anti-vasculaire	Le modèle a généré des images OCT post-thérapeutiques individualisées qui pourraient prédire la réponse à court terme du traitement pour la dégénérescence maculaire liée à l’âge
Lee et coll. [74]	GAN conditionnel (entrées multicanaux)	OCT rétinien (avec angiographie à la fluorescéine et angiographie à l’indocyanine verte)	Injection intravitréenne de facteur de croissance endothélial anti-vasculaire	Le modèle entraîné a généré des images de tomographie par cohérence optique (OCT) post-traitement de la dégénérescence maculaire néovasculaire liée à l’âge

Tableau (2.5)- Résumé de la revue de la littérature pour la tâche de prédiction post-intervention à l’aide du GAN dans les domaines d’imagerie ophtalmologique [115]

2.2.6 Extraction de caractéristiques

Une autre tâche qui n’appartenait pas à ces catégories est l’extraction de caractéristiques. Cette tâche se concentre sur l’aspect discriminant du GAN car les études ont directement utilisé les architectures du GAN pour détecter les pathologies. Schlegl et al. ont proposé une méthode de détection des anomalies utilisant un GAN dans le domaine OCT rétinien [93]. Ce modèle GAN a estimé l’espace latent via l’apprentissage de la cartographie inverse à partir des images d’entrée et a calculé les scores d’anomalie à partir de l’espace caractéristique des échantillons normaux. Cette architecture de détection des anomalies a été étendue avec succès à d’autres domaines, tels que la détection d’anomalies industrielles ou la détection de lésions thoraciques dans les images radiographiques [108]. Xie et al. ont construit un modèle GAN conditionnel modifié pour les images du fond d’œil ultra-large afin d’améliorer la détection des maladies de la rétine [105].

Le Tableau (2.6) présente les études qui ont porté sur la tâche d'extraction de caractéristiques à l'aide de GAN dans les domaines d'imagerie ophtalmologique [115] :

Publication	Technique de base	Domaine	Cible	Résumé
Schlegl et coll. [93]	f-AnoGAN (GAN de Wasserstein + cartographie de l'espace latent)	OCT rétinien	Détection du liquide intra-rétinien (détection d'anomalie OCT)	L'apprentissage non supervisé basé sur le GAN de données d'entraînement saines a été formé avec une cartographie rapide des images aux codages dans l'espace latent. Les anomalies ont été détectées via un score d'anomalie combiné basé sur une erreur de reconstruction d'image
Xie et coll. [105]	GAN conditionnel (avec encodeur d'attention et structure multi-branches)	Photographie du fond d'œil ultra-large (ophtalmoscopie laser à balayage)	Caractéristiques pour les maladies de la rétine	Le GAN basé sur l'encodeur d'attention et la structure multi-branches a été utilisé pour extraire les caractéristiques de la détection des maladies de la rétine. Le discriminateur dans le GAN a été modifié pour construire le classificateur afin de détecter les images de la maladie

Tableau (2.6)- Résumé de la revue de la littérature pour la tâche d'extraction de caractéristiques à l'aide de GAN dans les domaines d'imagerie ophtalmologique [115]

2.2.7 Autres applications

Les GANS ont été exploités pour d'autres applications moins courantes telles que la localisation de la pathologie rétinienne dans l'image du fond d'œil à l'aide de CycleGAN [117]. Dans cette tâche de localisation, la zone pathologique a été détectée en soustrayant l'image normale synthétisée de l'image pathologique.

Le recalage d'images est une autre tâche qui consiste à trouver la transformation géométrique permettant d'apparier structurellement les images. Cette application est importante dans le cas du transfert de domaines où l'apprentissage nécessite des paires d'images appariées. Mahapatra et al. ont montré qu'un auto-encodeur basé sur l'architecture GAN offrait de meilleures performances de recalage pour les images du fond d'œil et les images d'angiographie rétinienne

2.3 Conclusion

Dans ce chapitre, nous avons exposé les différentes utilisations des GANs dans le domaine médical et plus précisément en ophtalmologie. Nous avons présenté un résumé de la revue de la littérature pour chaque tâche réalisée à l'aide de GAN. Comparé à d'autres techniques d'analyse d'images médicales, nous avons constaté que le GAN n'en est encore qu'à ses débuts et le nombre de travaux connexes disponibles dans la littérature est relativement faible dans le domaine Ophtalmologique et plus particulièrement dans le cas de la Rétinopathie diabétique (RD). C'est pourquoi, nous nous sommes intéressés à cette pathologie. Dans le prochain chapitre, nous proposons une architecture d'un GAN qui permet la détection et la classification automatique de la RD .

Conception et réalisation d'un modèle GAN

3.1 Introduction

La rétinopathie diabétique (RD) est une maladie fréquente qui provoque une perte de vision, chez les personnes atteintes de diabète. Le diagnostic de la RD est long et difficile, même pour les ophtalmologistes. c'est pourquoi développer un modèles de classification automatique de la RD est important. L'utilisation d'un Réseau de neurones profond efficace nécessite une grande quantité de données diverses et équilibrées. Cependant, la distribution des données de RD sur les différents stades est extrêmement déséquilibrée, car les images anormales du fond de l'œil ne représentent qu'une petite partie. En plus du manque de données, les images du fond d'œil souffrent également des limites de l'appareil, de l'habileté de l'examineur, des variations de l'anatomie oculaire et de la transparence de l'axe visuel. C'est pourquoi, nous allons dans ce chapitre proposer une architecture d'un GAN qui permet de rehausser l'image pour éliminer les bruits et aussi de diagnostiquer et classifier la Rétinopathie Diabétique (RD) à partir d'une image réelle d'un fond d'œil.

Avant de présenter notre architecture GAN, nous allons d'abord donner un aperçu sur c'est quoi la RD.

3.2 Rétinopathie diabétique

— L'anatomie de l'œil

La rétine est une structure sphérique présente à l'intérieur, à l'arrière de l'œil. Sa fonction est de traiter les informations visuelles par l'intermédiaire des photorécepteurs présents dans l'œil, appelés bâtonnets et cônes. Au centre de la rétine se trouve une zone ronde et sombre appelée macula. Le point central de la macula appelé fovéa, est chargé de fournir une vision nette. Comme tout autre tissu de l'organisme, le tissu rétinien est alimenté en sang par le système vasculaire du corps, le disque optique, composé de la cupule optique est une

structure ou le nerf optique quitte l'oeil. C'est également le site où toutes les principales artères et veines entrent et sortent de l'oeil (voir Figure 3.1) [90].

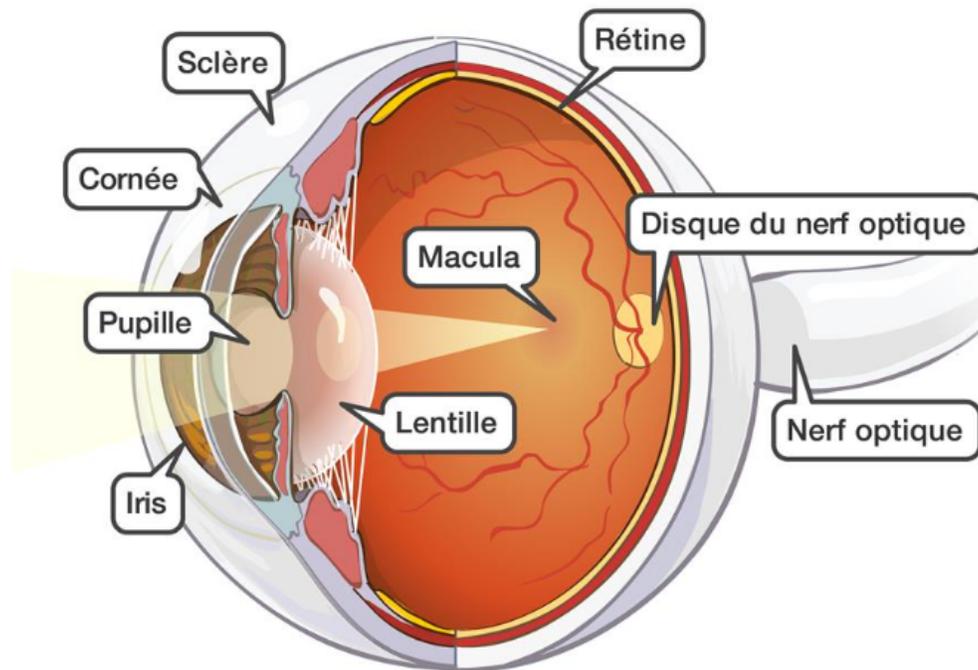


FIGURE 3.1 – Description de l'anatomie de l'oeil[90].

— La cause de la Rétinopathie Diabétique

Le sang est transporté vers les couches du tissu rétinien par des micro-vaisseaux sanguins qui nécessitent un taux de sucre sanguin maintenu et un flux sanguin non obstrué. Si de grandes quantités de sucres, tels que le glucose ou le fructose s'accumulent dans le sang, ces vaisseaux sanguins commencent à se détériorer en raison d'une mauvaise distribution de l'oxygène aux cellules. Des anomalies structurelles se produisent à la suite d'une diminution du taux métabolique, ce qui entraîne la RD [83].

— Les Différents stades de la Rétinopathie Diabétique

1. Rétinopathie non proliférante minime :

Le signal principal de ce stade est la présence des microanévrismes.

La Figure 3.2 montre un microanévrisme, et donc signe d'une rétinopathie non proliférante minime.



FIGURE 3.2 – Microanévrismes[83].

2. Rétinopathie non proliférante modérée :

Les symptômes qui caractérisent cette classe sont : les microanévrismes, exsudats secs, nodules cotonneux ("nodules dysoriques") et hémorragies rétiniennes punctiformes.

La Figure 3.3 montre la présence de microanévrismes et d'hémorragies de petite taille en nombre modéré, ainsi que de rares nodules cotonneux



FIGURE 3.3 – Rétinopathie diabétique non proliférante (RDNP) modérée[1]

3. Rétinopathie non proliférante sévère (rétinopathie préproliférante) :

Pour ce stade, les signes peuvent être des hémorragies intrarétiniennes sévères et microanévrismes, ou bien un perlage veineux défini dans deux quadrants ou plus, ou des hémorragies intrarétiniennes étendues, volumineuses ou en tache.

La Figure 3.4 montre les signes énoncés précédemment et qui caractérisent la rétinopathie non proliférante sévère.

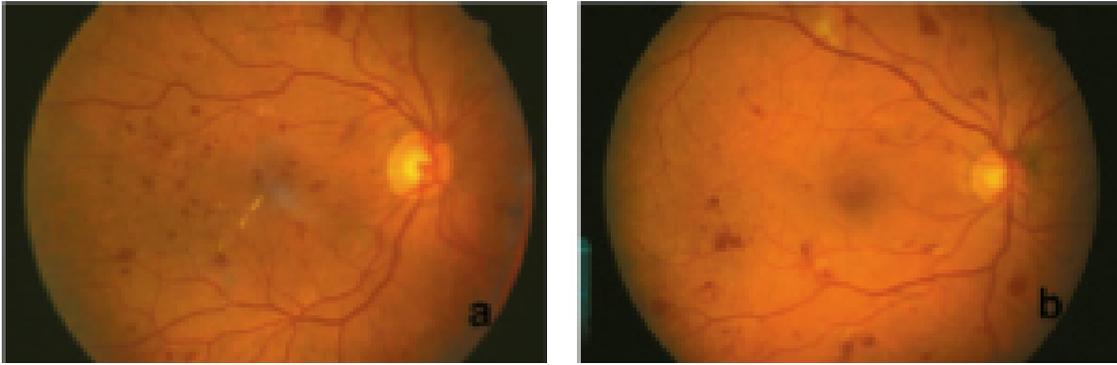


FIGURE 3.4 – Rétinopathie diabétique non proliférante sévère[1]

4. Rétinopathie proliférante :

Ce stade de la RD se caractérise par la néovascularisation, hémorragie vitréenne ou pré-rétinienne et le décollement de rétine par traction[1, 83].

La Figure 3.5 montre l'anatomie de l'oeil, en rouge c'est les signes de la rétinopathie proliférante.

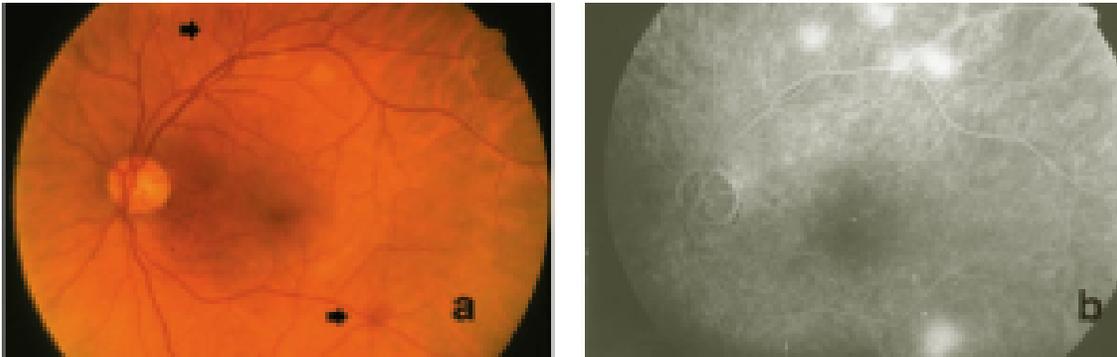


FIGURE 3.5 – Rétinopathie diabétique proliférante (RDP)[1]

3.3 Architecture du modèle GAN proposé

Pour pallier au problème du mauvais diagnostic et à celui des images bruitées, nous proposons une architecture d'un GAN qui permet d'améliorer la qualité de l'image et de classer "Rétinopathie diabétique" selon ses différents grades.

Le modèle que nous proposons permettra donc :

1. D'améliorer la qualité de l'image en prenant en entrée une image réelle d'un fond d'oeil au lieu de créer une image à partir d'un bruit.
2. De classer la RD selon son degré de gravité donc le GAN sera à plusieurs sorties au lieu de 2 (vrai ou faux)
3. Les images intermédiaires(générées) seront utilisées pour l'augmentation du dataset selon le grade de la RD.

L'architecture du GAN proposé utilise un modèle basé sur le réseau du générateur du modèle ESRGAN [73] pour l'amélioration de la qualité des images réelles et l'élimination des bruits et d'un réseau de neurones convolutif pour la classification de l'image.

Donc le générateur proposé est une exploitation du générateur de ESRGAN que nous avons appliqué aux images réelles de la RD, et le discriminateur est un réseau de neurones convolutif multiclassés qui permet de faire la classification de la rétinopathie diabétique .

Une image réelle d'un fond d'oeil est soumise au générateur qui va la prétraiter pour améliorer sa qualité visuelle et le discriminateur va la classer selon les différents stades de la RD ou la rejeter si l'image ne fait partie d'aucune des classes prédéfinies. La figure (3.6) présente le schéma général du modèle proposé.

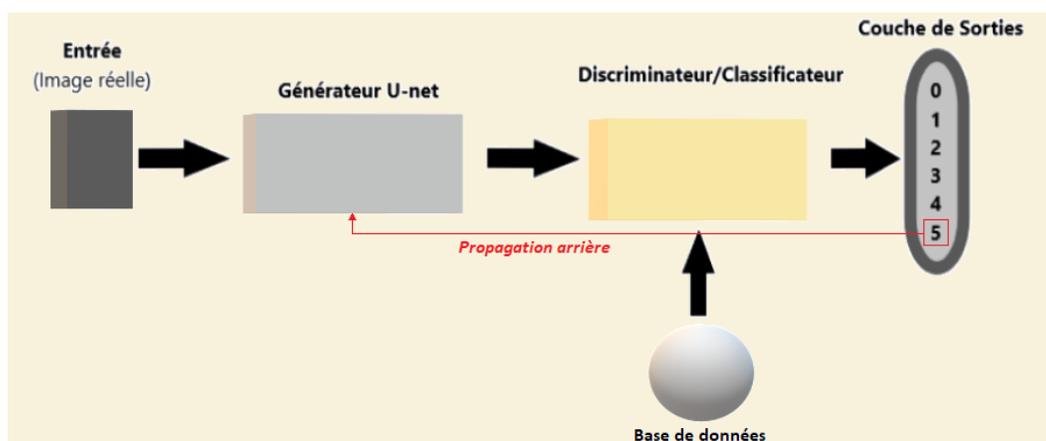


FIGURE 3.6 – Architecture générale proposée

3.3.1 Architecture du générateur

L'architecture utilisée pour le Générateur G est de type U-Net, illustré à la Figure 3.6.

Au coeur de cette architecture, nous utilisons trois couches convolutionnelles avec des petits noyaux 3x3 et 64 cartes de caractéristiques suivies de couches de normalisation par lots [94] et ParametricReLU [54] comme fonction d'activation voir Figure 3.7.

Après les deux étapes 'Extraction de caractéristique' et 'Réduction de la taille de l'image' qui se font respectivement au niveau des deux couches convolution et pooling, nous augmentons la résolution de l'image d'entrée en appliquant une déconvolution suivie d'un rééchelonnement par un pooling inverse dont l'indice a été sauvegardé lors du codage, et une dernière couche pour afficher la nouvelle image obtenue.

Normalisation par lot : C'est une technique de normalisation effectuée entre les couches d'un réseau neuronal plutôt que dans les données brutes. Cela se fait le long de mini-lots au lieu de l'ensemble complet de données. Il sert à accélérer l'entraînement et à utiliser des taux d'apprentissage plus élevés, ce qui facilite l'apprentissage.

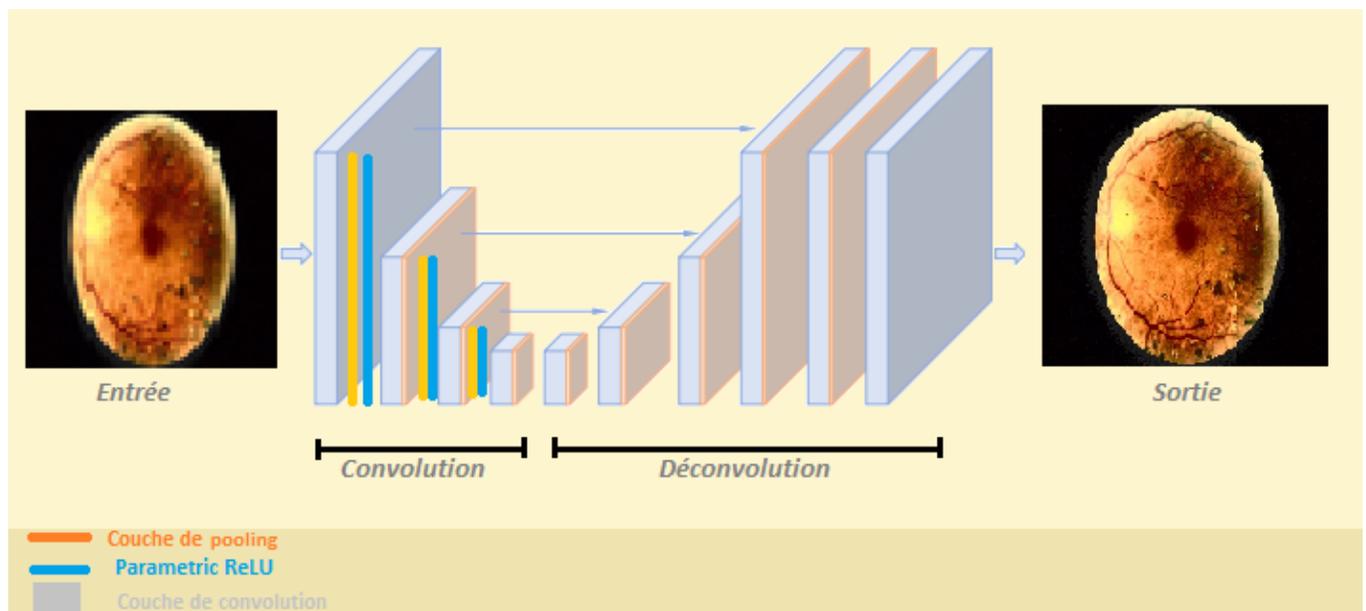


FIGURE 3.7 – Architecture du Générateur

3.3.2 Architecture du discriminateur

L'architecture de notre modèle discriminateur est basée sur deux étapes voir Figure 3.8 :

Étape 01 : Extraction de caractéristiques ;

Étape 02 : Classification.

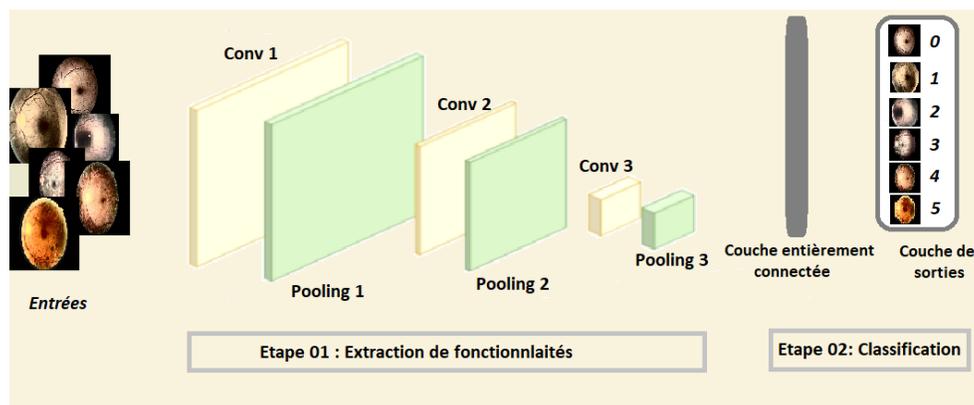


FIGURE 3.8 – Architecture du Discriminateur

Pour la première partie nous utilisons trois couches de convolution, chacune suivie d'une couche de mise en commun (Pooling) afin de pouvoir extraire les caractéristiques de l'image et réduire sa taille. Ensuite dans la deuxième partie nous utilisons une couche entièrement connectée suivie de la fonction d'activation Softmax pour pouvoir classer notre image dans l'une des 6 classes de la couche de sortie voir Figure 3.9 .

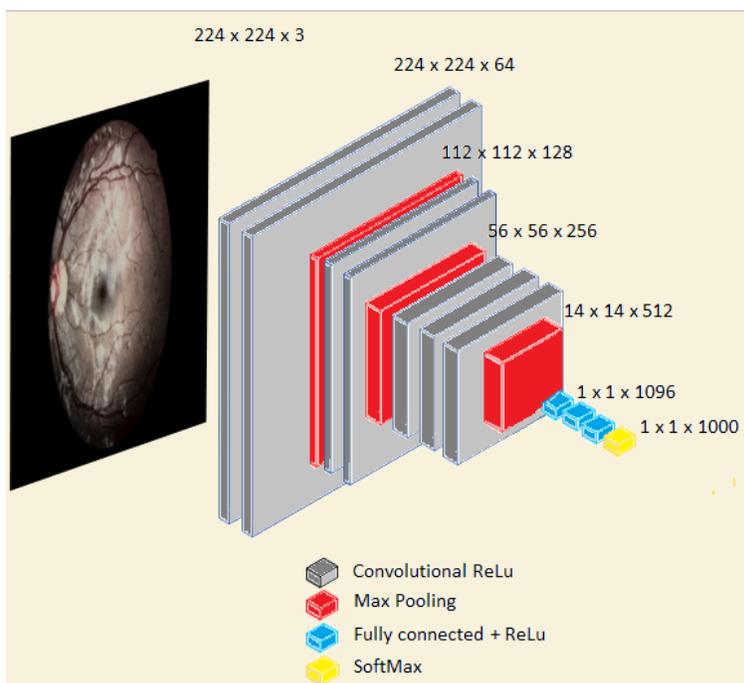


FIGURE 3.9 – Architecture détaillée du Discriminateur

3.4 Bases de données utilisées

Nous avons utilisé pour l'apprentissage de notre GAN la base de données "**Diabetic-Retinopathy**" [6] qui contient 35 152 images réelles de la rétinopathie diabétique. Les images sont classées dans 5 dossiers différents selon les stades de la maladie :

Dossier 0 : Absence de RD, 25836 images.

Dossier 1 : Stade 1 de RD, 2443 images.

Dossier 2 : Stade 2 de RD, 5292 images.

Dossier 3 : Stade 3 de RD, 873 images.

Dossier 4 : Stade 4 de RD, 708 images.

Et pour les tests, nous avons utilisé des images réelles collectées lors de notre stage à l'hôpital de Béjaïa mais qui restes minimales.

3.5 Apprentissage

Le discriminateur apprend d'abord avec la BDD à classer les images selon le grade de la maladie de RD. Une fois terminé, on fait rentrer l'image réelle qu'on souhaite traiter et classer dans le générateur.

Le générateur traite à son tour l'image et génère sa version améliorée .

Le discriminateur prend de nouveau en charge la sortie du générateur, et essaye de la classer parmi les stades de la RD, si le discriminateur réussit à le faire, il renvoie en sortie le numéro de la classe du stade e la (RD) à savoir : 0,1,2,3 ou 4 ; sinon, l'image est déclassée et le discriminateur renvoie un 5 en sortie et retourne l'image au générateur pour la retraiter une autre fois.

Toutes les images générées par le générateur sont enregistrées dans la base de donnée, ce qui pourrait remédier au problème d'insuffisance de données dans ce domaine.

3.6 Réalisation

Nous allons présenter, la partie implémentation qui s'est limité à la partie rehaussement de l'image. Ainsi que les différents résultats obtenus en testant le modèle sur différentes images réelles et floutées.

Le Tableau 1 représente les résultats générés par notre générateur GAN pour des images bruitées de différents stade de RD.

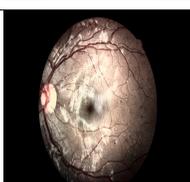
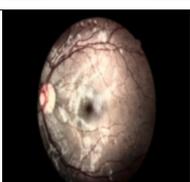
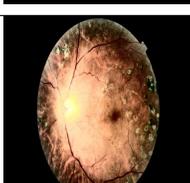
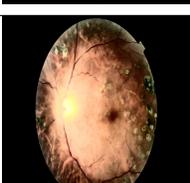
Stade	Image réelle	Image bruitée	Image GAN
0			
1			
2			
3			
4			

Tableau 1. Résultats générés par notre générateur GAN pour des images bruitées de différents stade de RD

En comparant les résultats du GAN avec les images réelles, on remarque que le GAN a pu générer des images qui portent les mêmes informations que l'image réelle, et a aussi supprimer le bruit et améliorer la qualité des images.

Le Tableau 2 représente les résultats générés par notre générateur GAN pour des images réelles de différents stade de RD.

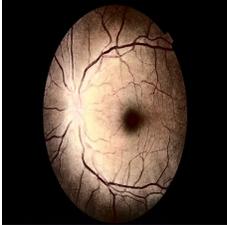
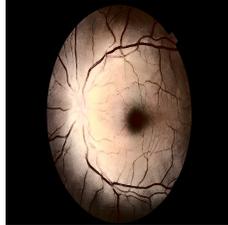
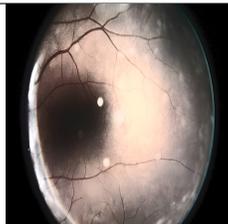
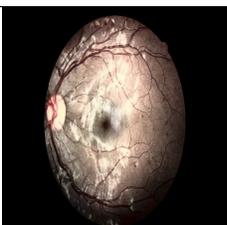
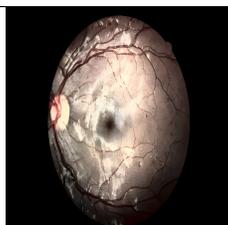
Stade	Image réelle	Image GAN
0		
1		
2		
3		
4		

Tableau 2. Résultats générés par notre générateur GAN pour des images réelles de différents stade de RD

On remarque que les images générées sont plus claires et contiennent moins de bruit que les images réelles (voir Figure 3.12), et on voit bien aussi que les vaisseaux rétiniens (voir Figure 3.10) et les microanévrismes (voir Figure 3.11) sont plus apparents et nettes dans l'image du GAN .

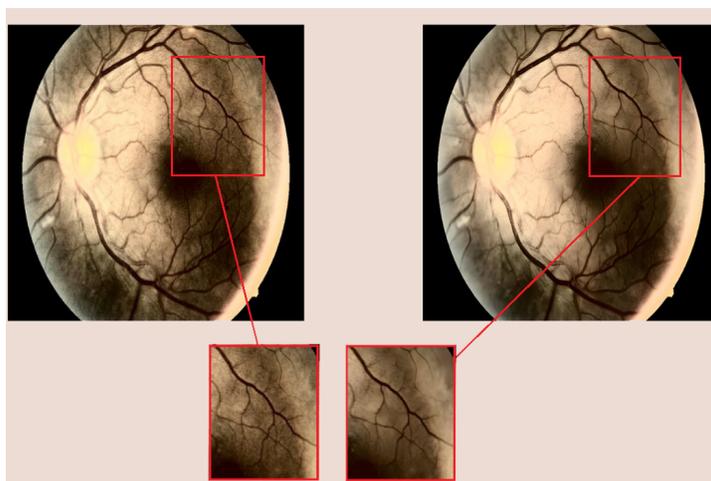


FIGURE 3.10 – Comparaison vaisseaux rétiniens

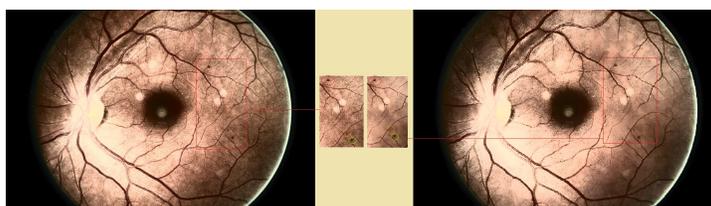


FIGURE 3.11 – Comparaison microanévrismes

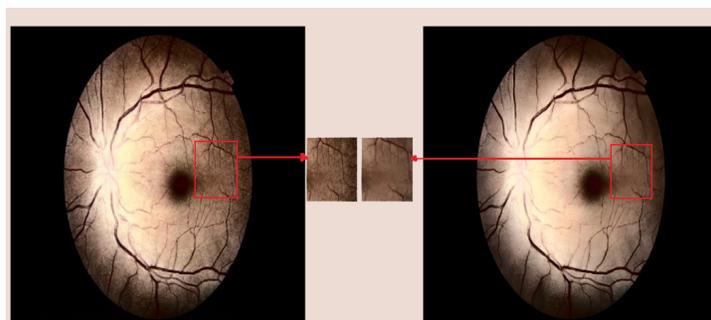


FIGURE 3.12 – Comparaison bruit

3.6.1 Environnement de développement

Les outils d'apprentissage profond permettent aux sciences des données (Data Scientists) de créer des programmes capables d'amener un ordinateur ou une machine à apprendre comme le cerveau humain et à traiter des données et des modèles avant d'exécuter des décisions.

La présentation suivante détaille les outils les plus couramment utilisés et les plus importants pour le développement de notre approche.

3.6.1.1 Python

Python est un langage de programmation interprété, orienté objet, de haut niveau et à sémantique dynamique. La syntaxe de Python, est simple et facile à apprendre, privilégie la lisibilité et réduit donc le coût de la maintenance des programmes. Python prend en charge les modules et les packages, ce qui encourage la modularité des programmes et la réutilisation du code Python est un langage de programmation de haut niveau, polyvalent et très populaire [46].

3.6.1.2 OpenCV

OpenCV (Open Source Computer Vision Library) est une bibliothèque logicielle open source de vision par ordinateur et d'apprentissage automatique. OpenCV a été construit pour fournir une infrastructure commune pour les applications de vision par ordinateur et pour accélérer l'utilisation de la perception artificielle dans les produits commerciaux. Étant un produit sous licence BSD, OpenCV permet aux entreprises d'utiliser et de modifier facilement le code. La bibliothèque compte plus de 2500 algorithmes optimisés, ce qui inclut un ensemble complet d'algorithmes de vision par ordinateur et d'apprentissage automatique classiques et de pointe. Ces algorithmes sont spécialisés dans le traitement d'images en temps réel d'où ils peuvent être utilisés pour détecter et reconnaître des visages, identifier des objets, classer des actions humaines dans des vidéos, suivre les mouvements de la caméra, suivre des objets en mouvement, extraire des modèles 3D d'objets, etc [30].

Dans le processus de l'apprentissage nous avons utilisé la version 3.2.0.

3.6.1.3 NumPy

NumPy est le package de base pour le calcul scientifique en Python. Il s'agit d'une bibliothèque Python qui fournit un objet tableau multidimensionnel, divers objets dérivés (tels que des tableaux et des tableaux cachés) et une variété de procédures pour des opérations rapides sur les tableaux, y compris la forme, la logique, le contrôle, l'organisation, les changements, I/O, transformées de Fourier discrètes, algèbre variable linéaire de base, opérations statistiques de base, simulation stochastique et bien plus encore [19].

3.6.1.4 Matplotlib

Matplotlib est une bibliothèque complète permettant de créer des visualisations statiques, animées et interactives en Python. Matplotlib rend les choses faciles et les choses difficiles possibles. Elle permet de créer des graphiques de qualité professionnelle, ainsi que des figures interactives pouvant être zoomées, panoramisées et actualisées tout en personnalisant le style visuel et la mise en page. Elle permet aussi de s'exporter vers de nombreux formats de fichiers [18].

3.6.1.5 TensorFlow

TensorFlow est une plateforme open-source pour la création d'applications d'apprentissage automatique. Il s'agit d'une bibliothèque de mathématiques symboliques qui utilise le flux de données et la programmation différentiable pour effectuer diverses tâches axées sur la formation et l'inférence de réseaux neuronaux profonds. Elle permet aux développeurs de créer des applications d'apprentissage automatique en utilisant divers outils, bibliothèques et ressources communautaires [21].

3.6.1.6 Keras

Keras offre des fonctionnalités minimales mais très productives grâce à sa bibliothèque d'apprentissage profond. Keras est écrit en Python comme une API d'apprentissage profond, et il fonctionne au-dessus de TensorFlow, une plateforme d'apprentissage automatique.

Keras a été développé pour permettre une expérimentation rapide. Il est facile à aborder et offre une interface très productive pour résoudre plusieurs problèmes d'apprentissage automatique en se concentrant sur une approche moderne de l'apprentissage profond. L'avantage essentiel de Keras est qu'il peut prendre l'idée d'un développeur et le guider vers des résultats définitifs [17].

3.6.1.7 Google Colaboratory

Google Colab est un produit de Google, comme son nom l'indique. Il s'agit essentiellement d'un environnement de bloc-notes gratuit qui fonctionne entièrement dans le nuage informatique. Il dispose de fonctionnalités qui aident à modifier des documents de la même manière que travaille Google Docs. Colab prend en charge de nombreuses bibliothèques d'apprentissage automatique populaires et de haut niveau qui peuvent être facilement chargées dans votre notebook.

Google Colab nous offre trois types de runtime pour nos ordinateurs portables : CPUs, GPUs, et TPUs, Colab nous offre un total de 12 heures d'exécution continue. Après cela, toute la machine virtuelle est effacée et nous devons repartir de zéro. à cause de limite d'utilisation des ressources google Colab.

Nous pouvons exécuter plusieurs instances CPU, GPU et TPU simultanément dans Google collab, mais les ressources sont partagées entre ces instances [20].

Pour notre apprentissage nous avons utilisé les ressources de Colab avec la GPU k80 avec RAM 13 GO et 12GO de VRAM.

3.6.2 Implémentation

1. Préparation et importation du modèle générateur ESRGAN :

```
!git clone https://github.com/xinntao/Real-ESRGAN.git
%cd Real-ESRGAN
# Set up the environment
!pip install basicsr
!pip install faceplib
!pip install gfpgan
!pip install -r requirements.txt
!python setup.py develop
```

2. Chargement des image de notre BDD de RD :

```
[ ] importer le
à partir de fichiers d'importation google.colab
import shutil

upload_folder = 'télécharger'
result_folder = 'résultats'

si os.path.isdir(upload_folder) :
    shutil.rmtree(upload_folder)
si os.path.isdir(result_folder) :
    shutil.rmtree(result_folder)
os.mkdir(upload_folder)
os.mkdir(result_folder)

# télécharger des images
téléchargé = files.upload()
pour le nom de fichier dans uploaded.keys():
    dst_path = os.path.join(upload_folder, nom de fichier)
    print(f'move {filename} vers {dst_path}')
    shutil.move(nom de fichier, dst_path)
```

3. Inférence :

```
[ ] # s'il manque de mémoire, essayez d'utiliser l'option '--tile'
# Nous suréchantillonons l'image avec le facteur d'échelle X3.5
! python inference_realesrgan.py -n RealESRGAN_x4plus -i upload --outscale 3.5 --face_enhance
# Arguments
# -n, --model_name : noms de modèles
# -i, --input: dossier d'entrée ou image
# --outscale: Échelle de sortie, peut être un facteur d'échelle arbitraire.
```

4. Visualisation :

```
[ ] # utilitaires pour la visualisation
importer cv2
importer matplotlib.pyplot en tant que plt
affichage def (img1, img2):
    fig = plt.figure(figsize=(25, 10))
    ax1 = fig.add_subplot(1, 2, 1)
    plt.title('Image d'entrée', fontsize=16)
    ax1.axis('off')
    ax2 = fig.add_subplot(1, 2, 2)
    plt.title('Sortie Real-ESRGAN', fontsize=16)
    ax2.axis('off')
    ax1.imshow(img1)
    ax2.imshow(img2)
def imread(img_path):
    img = cv2.imread(img_path)
    img = cv2.cvtColor(img, cv2.COLOR_BGR2RGB)
    retourner img

# afficher chaque image dans le dossier de téléchargement
importer le
importation de globe

input_folder = 'télécharger'
result_folder = 'résultats'
input_list = trié(glob.glob(os.path.join(input_folder, '*')))
output_list = trié(glob.glob(os.path.join(result_folder, '*')))
pour input_path, output_path en zip(input_list, output_list):
    img_input = imread(input_path)
    img_output = imread(output_path)
    affichage(img_input, img_output)
```

5. Téléchargement des résultats

```
▶ # Download the results
zip_filename = 'result.zip'
if os.path.exists(zip_filename):
    os.remove(zip_filename)
os.system(f"zip -r -j {zip_filename} results/*")
files.download(zip_filename)
```

3.7 Conclusion

Dans ce chapitre, après avoir défini la RD ainsi que ses différents stades, nous avons proposé une architecture d'un GAN qui permet non seulement d'améliorer la qualité des images du fond d'oeil avec un générateur de type U-net, mais aussi de détecter et classer automatiquement la RD grâce à un réseau de neurones convolutif multiclassés dit discriminateur. Nous avons montré que les résultats d'expérimentation obtenus en testant les générateurs sont fort intéressants.

Conclusion Générale

La Rétinopathie Diabétique est une pathologie grave, sa détection permet d'éviter la cécité aux malades. La majorité des méthodes d'analyse d'images médicales sont des méthodes supervisées, ce qui requiert une grande quantité de données étiquetées. Les images médicales souffrent généralement du bruit qui les rend illisibles ou parfois les symptômes de la pathologie ne sont pas facilement décelable à l'oeil nu.

Dans ce travail nous avons proposé une architecture GAN qui permet le prétraitement, et la classification des images de la rétinopathie diabétique.

Pour cela nous avons proposé une architecture GAN dont le générateur est de type U-Net et le discriminateur un réseau de neurones convolutif à plusieurs sorties, qui permet de classer l'image générée selon les différents degrés de la maladie.

Nous avons uniquement réalisé et testé la partie générateur du GAN proposé. Pour améliorer la qualité de l'image nous avons exploité le réseau ESRGAN pour le traitement des images de RD et nous avons maîtriser plusieurs environnements et outils de développement.

Nous avons testé le générateur sur des images bruitées et sur des images réelles et les résultats sont prometteurs. Toutes les images générées ont été ajoutées a la BDD, ce qui répond au problème d'insuffisance de données étiquetées.

Beaucoup de travail reste à faire ; c'est pourquoi nous proposons comme perspective de finir le travail en réalisant la partie classification du discriminateur, de tester le GAN sur des images avec différent type de bruit et soumettre les résultats à un spécialiste pour vérifier si les images obtenues facilitent la reconnaissance de la (RD).

Bibliographie

- [1] <http://campus.cerimes.fr/ophtalmologie/enseignement/ophtalmo16/site/html/3331.html> : :
text = la%20r%c3%a9tinopathie%20diab%c3%a9tique%20d%c3%a9bute%20par, de%20r%c3%a9tinop
11/09/2022.
- [2] <https://fr.acervolima.com/fonctions-d-activation-dans-les-reseaux-de-neurones/>, Consulter le :
11/09/2022.
- [3] <https://ichi.pro/fr/fonctions-d-activation-bases-de-sigmoid-relu-leaky-relu-et-softmax-pour-les-reseaux-de-neurones-et-le-deep-learning-155703049115934>, Consulter le : 11/09/2022.
- [4] <https://machinelearningmastery.com/a-gentle-introduction-to-pix2pix-generative-adversarial-network/>, Consulter le : 11/09/2022.
- [5] <https://www.google.com/search?q=r%c3%a9seaux+antagonistes+g%c3%a9n%c3%a9ratifsource=lmstbm1366bih=625dpr=1>, Consulter le : 11/09/2022.
- [6] <https://www.kaggle.com/datasets/mustaqimabrar/diabeticretinopathy>, Consulter le :
11/09/2022.
- [7] http://www.gabormelli.com/rkb/perceptron_fonction, Consulter le : 11/09/2022.
- [8] <https://inside-machinelearning.com/cnn-couche-de-convolution>, consulter le : 19/07/2022.
- [9] <https://dataanalyticspost.com/talents-des-gan/>, consulter le : 20/07/2022.
- [10] <https://fr.acervolima.com/reseaux-contradictaires-generatifs-gan-une-introduction/>, consulter le :
20/07/2022.
- [11] <https://machinelearningmastery.com/books-on-generative-adversarial-networks-gans/>, consulter
le : 20/07/2022.
- [12] <https://machinelearningmastery.com/what-are-generative-adversarial-networks-gans/>, consulter
le : 20/07/2022.
- [13] https://github.com/mingtaoguo/dcgan_wgan_gan-gp_lsgan_sngan_rsgan_began_acgan_pggan_tensorflow, consulte
20/08/2022.
- [14] <https://sherry40931.github.io/paper/2018/07/23/cyclegan.html>, consulter le : 20/08/2022.
- [15] <https://www.xenonstack.com/insights/generative-adversarial-networks>, consulter le : 20/08/2022.

- [16] <https://www.analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/>, consulté le : 22/07/2022.
- [17] <https://keras.io/about/>, Consulté le : 23/06/2022.
- [18] <https://matplotlib.org/>, Consulté le : 23/06/2022.
- [19] <https://numpy.org/doc/stable/user/whatisnumpy.html>, consulté le : 23/06/2022.
- [20] <https://research.google.com/colaboratory/faq.html>, Consulté le : 23/06/2022.
- [21] <https://www.guru99.com/what-is-tensorflow.html>, Consulté le : 23/06/2022.
- [22] <https://medium.com/analytics-vidhya/vanishing-and-exploding-gradient-problems-c9408>, consulté le : 28/08/2022.
- [23] Hazem Abdelmotaal, Ahmed A Abdou, Ahmed F Omar, Dalia Mohamed El-Sebaity, and Khaled Abdelazeem. Pix2pix conditional generative adversarial networks for scheinpflug camera color-coded corneal tomography image generation. *Translational Vision Science & Technology*, 10(7) :21–21, 2021.
- [24] Kailash Ahirwar. *Generative adversarial networks projects : Build next-generation generative models using TensorFlow and Keras*. Packt Publishing Ltd, 2019.
- [25] Alexia Audevart and Magaly Alonzo. *Apprendre demain : Quand intelligence artificielle et neurosciences révolutionnent l'apprentissage*. Dunod, 2019.
- [26] Chloé-Agathe Azencott. *Introduction au machine learning*. Dunod, 2019.
- [27] Anurag Bhardwaj, Wei Di, and Jianing Wei. *Deep Learning Essentials : Your hands-on guide to the fundamentals of deep learning and neural network modeling*. Packt Publishing Ltd, 2018.
- [28] Xuesheng Bian, Xiongbiao Luo, Cheng Wang, Weiquan Liu, and Xiuhong Lin. Optic disc and optic cup segmentation based on anatomy guided cascade network. *Computer Methods and Programs in Biomedicine*, 197 :105717, 2020.
- [29] BAYOU Bilal. Mémoire de master.
- [30] Gary Bradski and Adrian Kaehler. *Learning OpenCV : Computer vision with the OpenCV library*. " O'Reilly Media, Inc.", 2008.
- [31] Jason Brownlee. A gentle introduction to generative adversarial networks (gans). *Retrieved June, 17 :2019*, 2019.
- [32] Philippe M Burlina, Neil Joshi, Katia D Pacheco, TY Alvin Liu, and Neil M Bressler. Assessment of deep generative models for high-resolution synthetic retinal image generation of age-related macular degeneration. *JAMA ophthalmology*, 137(3) :258–264, 2019.
- [33] Frédéric Charbonnier. *Etude et application des réseaux adverses génératifs à la conversion de voix*. PhD thesis, Haute école de gestion de Genève, 2021.
- [34] Xi Chen, Yan Duan, Rein Houthoofd, John Schulman, Ilya Sutskever, and Pieter Abbeel. Info-gan : Interpretable representation learning by information maximizing generative adversarial nets. *Advances in neural information processing systems*, 29, 2016.

- [35] Zailiang Chen, Ziyang Zeng, Hailan Shen, Xianxian Zheng, Peishan Dai, and Pingbo Ouyang. Dn-gan : Denoising generative adversarial networks for speckle noise reduction in optical coherence tomography images. *Biomedical Signal Processing and Control*, 55 :101632, 2020.
- [36] Haris Cheong, Sripad Krishna Devalla, Tan Hung Pham, Liang Zhang, Tin Aung Tun, Xiaofei Wang, Shamira Perera, Leopold Schmetterer, Tin Aung, Craig Boote, et al. Dshadowgan : a deep learning approach to remove shadows from optical coherence tomography images. *Translational Vision Science & Technology*, 9(2) :23–23, 2020.
- [37] Pedro Costa, Adrian Galdran, Maria Inês Meyer, Michael David Abramoff, Meindert Niemeijer, Ana Maria Mendonça, and Aurélio Campilho. Towards adversarial retinal image synthesis. *arXiv preprint arXiv :1701.08974*, 2017.
- [38] Pedro Costa, Adrian Galdran, Maria Ines Meyer, Meindert Niemeijer, Michael Abràmoff, Ana Maria Mendonça, and Aurélio Campilho. End-to-end adversarial retinal image synthesis. *IEEE transactions on medical imaging*, 37(3) :781–791, 2017.
- [39] Antonia Creswell, Tom White, Vincent Dumoulin, Kai Arulkumaran, Biswa Sengupta, and Anil A Bharath. Generative adversarial networks : An overview. *IEEE signal processing magazine*, 35(1) :53–65, 2018.
- [40] RAOUNAK LILIA DAHAH. La détection de la colère chez le conducteur en utilisant le deep learning. 2020.
- [41] Vineeta Das, Samarendra Dandapat, and Prabin Kumar Bora. Unsupervised super-resolution of oct images using generative adversarial network for improved age-related macular degeneration diagnosis. *IEEE Sensors Journal*, 20(15) :8746–8756, 2020.
- [42] Culture de la Tunisie. Wikipédia : l’encyclopédie libre [en ligne], dernière modification de la page 23 juin 2020 à 18 : 54,[consulté le 22 janvier 2022]. *Disponible à l’adresse : <https://fr.wikipedia.org/w/index.php>*.
- [43] Andres Diaz-Pinto, Adrián Colomer, Valery Naranjo, Sandra Morales, Yanwu Xu, and Alejandro F Frangi. Retinal image synthesis and semi-supervised learning for glaucoma assessment. *IEEE transactions on medical imaging*, 38(9) :2211–2218, 2019.
- [44] Trad Housseem Eddine. La détection d’objet avec opencv et deep learning. 2020.
- [45] Mesbah Fethia. Détection d’objets par deep neural network à l’aide du modèle yolo en temps réel. 2021.
- [46] Patrick Fuchs and Pierre Poulain. *Cours de python*. Lulu. com, 2020.
- [47] Aurélien Géron. Deep computer vision using convolutional neural network. *Hands-On Machine Learning with Scikit-Learn, Keras & tensorflow, 2nd ed.*, Sebastopol : O’Reilly Media, Inc, pages 445–496, 2019.
- [48] Aurélien Géron. *Machine Learning avec Scikit-Learn : Mise en oeuvre et cas concrets*. Dunod, 2019.

- [49] Ian Goodfellow. Nips 2016 tutorial : Generative adversarial networks. *arXiv preprint arXiv :1701.00160*, 2016.
- [50] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. *Advances in neural information processing systems*, 27, 2014.
- [51] Ahnul Ha, Sukkyu Sun, Young Kook Kim, Jinho Lee, Jin Wook Jeoung, Hee Chan Kim, and Ki Ho Park. Deep-learning-based enhanced optic-disc photography. *PloS one*, 15(10) :e0239913, 2020.
- [52] Heba Hakim and Ali Fadhil. Survey : Convolution neural networks in object detection. In *Journal of Physics : Conference Series*, volume 1804, page 012095. IOP Publishing, 2021.
- [53] Kerry J Halupka, Bhavna J Antony, Matthew H Lee, Katie A Lucy, Ravneet S Rai, Hiroshi Ishikawa, Gadi Wollstein, Joel S Schuman, and Rahil Garnavi. Retinal optical coherence tomography image enhancement via deep learning. *Biomedical optics express*, 9(12) :6205–6221, 2018.
- [54] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Delving deep into rectifiers : Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision*, pages 1026–1034, 2015.
- [55] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778, 2016.
- [56] Xingxin He, Leyuan Fang, Hossein Rabbani, Xiangdong Chen, and Zhimin Liu. Retinal optical coherence tomography image classification with label smoothing generative adversarial network. *Neurocomputing*, 405 :37–47, 2020.
- [57] Morgan Heisler, Mahadev Bhalla, Julian Lo, Zaid Mammo, Sieun Lee, Myeong Jin Ju, Mirza Faisal Beg, and Marinko V Sarunic. Semi-supervised deep learning based 3d analysis of the peripapillary region. *Biomedical optics express*, 11(7) :3843–3856, 2020.
- [58] Yongqiang Huang, Zexin Lu, Zhimin Shao, Maosong Ran, Jiliu Zhou, Leyuan Fang, and Yi Zhang. Simultaneous denoising and super-resolution of optical coherence tomography images based on generative adversarial network. *Optics express*, 27(9) :12289–12307, 2019.
- [59] Sergey Ioffe and Christian Szegedy. Batch normalization : Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*, pages 448–456. PMLR, 2015.
- [60] Talha Iqbal and Hazrat Ali. Generative adversarial network for medical images (mi-gan). *Journal of medical systems*, 42(11) :1–11, 2018.
- [61] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, and Alexei A Efros. Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1125–1134, 2017.

- [62] Lie Ju, Xin Wang, Xin Zhao, Paul Bonnington, Tom Drummond, and Zongyuan Ge. Leveraging regular fundus images for training uwf fundus diagnosis models via adversarial learning and pseudo-labeling. *IEEE Transactions on Medical Imaging*, 40(10) :2911–2925, 2021.
- [63] Shreya Kadambi, Zeya Wang, and Eric Xing. Wgan domain adaptation for the joint optic disc-and-cup segmentation in fundus images. *International Journal of Computer Assisted Radiology and Surgery*, 15(7) :1205–1213, 2020.
- [64] Asifullah Khan, Anabia Sohail, Umme Zahoora, and Aqsa Saeed Qureshi. A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53(8) :5455–5516, 2020.
- [65] Saad M Khan, Xiaoxuan Liu, Siddharth Nath, Edward Korot, Livia Faes, Siegfried K Wagner, Pearse A Keane, Neil J Sebire, Matthew J Burton, and Alastair K Denniston. A global review of publicly available datasets for ophthalmological imaging : barriers to access, usability, and generalisability. *The Lancet Digital Health*, 3(1) :e51–e66, 2021.
- [66] Zakir Khan Khan, Arif Iqbal Umar, Syed Hamad Shirazi, Asad Rasheed, Abdul Qadir, and Sarah Gul. Image based analysis of meibomian gland dysfunction using conditional generative adversarial neural network. *BMJ Open Ophthalmology*, 6(1) :e000436, 2021.
- [67] Amal Kilani, Ahmed Ben Hamida, and Habib Hamam. Artificial intelligence review. In *Encyclopedia of Information Science and Technology, Fourth Edition*, pages 106–119. IGI Global, 2018.
- [68] Kwang Gi Kim. Book review : Deep learning. *Healthcare informatics research*, 22(4) :351–354, 2016.
- [69] Jason Kugelman, David Alonso-Caneiro, Scott A Read, Stephen J Vincent, Fred K Chen, and Michael J Collins. Data augmentation for patch-based oct chorio-retinal segmentation using generative adversarial networks. *Neural Computing and Applications*, 33(13) :7393–7408, 2021.
- [70] Georgios Lazaridis, Marco Lorenzi, Jibrán Mohamed-Noriega, Soledad Aguilar-Munoa, Katsuyoshi Suzuki, Hiroki Nomoto, Sebastien Ourselin, David F Garway-Heath, David P Crabb, Catey Bunce, et al. Oct signal enhancement with deep learning. *Ophthalmology Glaucoma*, 4(3) :295–304, 2021.
- [71] Georgios Lazaridis, Marco Lorenzi, Sebastien Ourselin, and David Garway-Heath. Improving statistical power of glaucoma clinical trials using an ensemble of cyclical generative adversarial networks. *Medical Image Analysis*, 68 :101906, 2021.
- [72] Yann Le Cun. *Quand la machine apprend : la révolution des neurones artificiels et de l'apprentissage profond*. Odile Jacob, 2019.
- [73] Christian Ledig, Lucas Theis, Ferenc Huszár, Jose Caballero, Andrew Cunningham, Alejandro Acosta, Andrew Aitken, Alykhan Tejani, Johannes Totz, Zehan Wang, et al. Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4681–4690, 2017.
- [74] Hyungwoo Lee, Seungmin Kim, Myung Ae Kim, Hyewon Chung, and Hyung Chan Kim. Post-treatment prediction of optical coherence tomography using a conditional generative adversarial network in age-related macular degeneration. *Retina*, 41(3) :572–580, 2021.

- [75] Shaochong Liu, Xiang Li, Yuchen Jiang, Hao Luo, Yanhui Gao, and Shen Yin. Integrated learning approach based on fused segmentation information for skeletal fluorosis diagnosis and severity grading. *IEEE Transactions on Industrial Informatics*, 17(11) :7554–7563, 2021.
- [76] TY Alvin Liu, Sina Farsiu, and Daniel S Ting. Generative adversarial networks to predict treatment response for neovascular age-related macular degeneration : interesting, but is it useful?, 2020.
- [77] Yutong Liu, Jingyuan Yang, Yang Zhou, Weisen Wang, Jianchun Zhao, Weihong Yu, Dingding Zhang, Dayong Ding, Xirong Li, and Youxin Chen. Prediction of oct images of short-term response to anti-vegf treatment for neovascular age-related macular degeneration using generative adversarial network. *British Journal of Ophthalmology*, 104(12) :1735–1740, 2020.
- [78] Yuhao Luo, Kun Chen, Lei Liu, Jicheng Liu, Jianbo Mao, Genjie Ke, and Mingzhai Sun. Dehaze of cataractous retinal images using an unpaired generative adversarial network. *IEEE Journal of Biomedical and Health Informatics*, 24(12) :3374–3383, 2020.
- [79] Andrew L Maas, Awni Y Hannun, Andrew Y Ng, et al. Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml*, volume 30, page 3. Citeseer, 2013.
- [80] Dwarikanath Mahapatra, Behzad Bozorgtabar, and Rahil Garnavi. Image super-resolution using progressive generative adversarial networks for medical image analysis. *Computerized Medical Imaging and Graphics*, 71 :30–39, 2019.
- [81] Dwarikanath Mahapatra and Zongyuan Ge. Training data independent image registration using generative adversarial networks and domain adaptation. *Pattern Recognition*, 100 :107109, 2020.
- [82] Om Prakash Mahela, Neeraj Gupta, Mahdi Khosravy, and Nilesh Patel. Comprehensive overview of low voltage ride through methods of grid integrated wind generator. *IEEE Access*, 7 :99299–99326, 2019.
- [83] Pascale Massin. Dépistage de la rétinopathie diabétique. *Sang Thrombose Vaisseaux*, 15(5) :249–255, 2003.
- [84] Mehran Mehralian and Babak Karasfi. Rdcgan : Unsupervised representation learning with regularized deep convolutional generative adversarial networks. In *2018 9th Conference on Artificial Intelligence and Robotics and 2nd Asia-Pacific International Symposium*, pages 31–38. IEEE, 2018.
- [85] Sinh-Ngoc Nguyen, Van-Quyet Nguyen, Jintae Choi, and Kyungbaek Kim. Design and implementation of intrusion detection system using convolutional neural network for dos detection. In *Proceedings of the 2nd international conference on machine learning and soft computing*, pages 34–38, 2018.
- [86] Jiahong Ouyang, Tejas Sudharshan Mathai, Kira Lathrop, and John Galeotti. Accurate tissue interface segmentation via adversarial pre-segmentation of anterior segment oct images. *Biomedical Optics Express*, 10(10) :5291–5324, 2019.
- [87] Kyeong-Beom Park, Sung Ho Choi, and Jae Yeol Lee. M-gan : Retinal blood vessel segmentation by balancing losses through stacked deep fully convolutional networks. *IEEE Access*, 8 :146308–146322, 2020.

- [88] Alec Radford, Luke Metz, and Soumith Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv :1511.06434*, 2015.
- [89] Sadaqat Ali Rammy, Waseem Abbas, Naqy-Ul Hassan, Asif Raza, and Wu Zhang. Cpgan : Conditional patch-based generative adversarial network for retinal vesselsegmentation. *IET Image Processing*, 14(6) :1081–1090, 2020.
- [90] Gabriel Renard, Christian Lemasson, and Henry Saraux. *Anatomie de l’oeil et de ses annexes*. Masson Paris, 1965.
- [91] Stéphane Roder. *Guide pratique de l’intelligence artificielle dans l’entreprise : Anticiper les transformations, mettre en place des solutions*. Editions Eyrolles, 2019.
- [92] Arthur Lee Samuel. Computer checkers (draughts) development. *intelligence (AI)*, 1 :1, 1950.
- [93] Thomas Schlegl, Philipp Seeböck, Sebastian M Waldstein, Georg Langs, and Ursula Schmidt-Erfurth. f-anogan : Fast unsupervised anomaly detection with generative adversarial networks. *Medical image analysis*, 54 :30–44, 2019.
- [94] Hicham Mohamed SEKKIL and Mahmoud MEBROUKI. *Etude comparative entre les différentes architectures des réseaux de neurones convolutifs (CNNs) pour la détection de la fatigue du conducteur*. PhD thesis, Directeur : Melle. Imane NEDAJR/Co-Directeur : M. MEGNAFI Hichem, 2021.
- [95] Wenzhe Shi, Jose Caballero, Ferenc Huszár, Johannes Totz, Andrew P Aitken, Rob Bishop, Daniel Rueckert, and Zehan Wang. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1874–1883, 2016.
- [96] YiRang Shin, Jaemoon Yang, and Young Han Lee. Deep generative adversarial networks : applications in musculoskeletal imaging. *Radiology : Artificial Intelligence*, 3(3), 2021.
- [97] Jaemin Son, Sang Jun Park, and Kyu-Hwan Jung. Towards accurate segmentation of retinal vessels and the optic disc in fundoscopic images with generative adversarial networks. *Journal of digital imaging*, 32(3) :499–512, 2019.
- [98] Vera Sorin, Yiftach Barash, Eli Konen, and Eyal Klang. Creating artificial images for radiology applications using generative adversarial networks (gans)—a systematic review. *Academic radiology*, 27(8) :1175–1185, 2020.
- [99] K Suganthi et al. Review of medical image synthesis using gan techniques. In *ITM Web of Conferences*, volume 37, page 01005. EDP Sciences, 2021.
- [100] Alireza Tavakkoli, Sharif Amit Kamran, Khondker Fariha Hossain, and Stewart Lee Zuckerbrod. A novel deep learning conditional generative adversarial network for producing angiography images from retinal fundus photographs. *Scientific Reports*, 10(1) :1–15, 2020.
- [101] Aurélien Vannieuwenhuyze. *Intelligence artificielle vulgarisée : Le Machine Learning et le Deep Learning par la pratique*. Éditions ENI., 2019.

- [102] Shujun Wang, Lequan Yu, Xin Yang, Chi-Wing Fu, and Pheng-Ann Heng. Patch-based output space adversarial learning for joint optic disc and cup segmentation. *IEEE transactions on medical imaging*, 38(11) :2485–2495, 2019.
- [103] Shuqiang Wang, Xiangyu Wang, Yong Hu, Yanyan Shen, Zhile Yang, Min Gan, and Baiying Lei. Diabetic retinopathy diagnosis using multichannel generative adversarial network with semisupervision. *IEEE Transactions on Automation Science and Engineering*, 18(2) :574–585, 2020.
- [104] Menglin Wu, Xinxin Cai, Qiang Chen, Zexuan Ji, Sijie Niu, Theodore Leng, Daniel L Rubin, and Hyunjin Park. Geographic atrophy segmentation in sd-oct images using synthesized fundus autofluorescence imaging. *Computer Methods and Programs in Biomedicine*, 182 :105101, 2019.
- [105] Hai Xie, Haijun Lei, Xianlu Zeng, Yejun He, Guozhen Chen, Ahmed Elazab, Guanghui Yue, Jiantao Wang, Guoming Zhang, and Baiying Lei. Amd-gan : attention encoder and multi-branch structure based generative adversarial networks for fundus disease detection from scanning laser ophthalmoscopy images. *Neural Networks*, 132 :477–490, 2020.
- [106] Jingwen Yang, Xinran Dong, Yu Hu, Qingsheng Peng, Guihua Tao, Yangming Ou, Hongmin Cai, and Xiaohong Yang. Fully automatic arteriovenous segmentation in retinal images via topology-aware generative adversarial networks. *Interdisciplinary Sciences : Computational Life Sciences*, 12(3) :323–334, 2020.
- [107] Tiejun Yang, Tingting Wu, Lei Li, and Chunhua Zhu. Sud-gan : deep convolution generative adversarial network combined with short connection and dense block for retinal vessel segmentation. *Journal of digital imaging*, 33(4) :946–957, 2020.
- [108] Xin Yi, Ekta Walia, and Paul Babyn. Generative adversarial network in medical imaging : A review. *Medical image analysis*, 58 :101552, 2019.
- [109] Erdost Yıldız, Abdullah Taha Arslan, Ayşe Yıldız Taş, Ali Faik Acer, Sertaç Demir, Afsun Şahin, and Duygun Erol Barkana. Generative adversarial network based automatic segmentation of corneal subbasal nerves on in vivo confocal microscopy images. *Translational Vision Science & Technology*, 10(6) :33–33, 2021.
- [110] Tae Keun Yoo, Joon Yul Choi, and Hong Kyu Kim. CycleGAN-based deep learning technique for artifact reduction in fundus photography. *Graefe’s Archive for Clinical and Experimental Ophthalmology*, 258(8) :1631–1637, 2020.
- [111] Tae Keun Yoo, Joon Yul Choi, and Hong Kyu Kim. A generative adversarial network approach to predicting postoperative appearance after orbital decompression surgery for thyroid eye disease. *Computers in biology and medicine*, 118 :103628, 2020.
- [112] Tae Keun Yoo, Joon Yul Choi, and Hong Kyu Kim. Feasibility study to improve deep learning in oct diagnosis of rare retinal diseases with few-shot classification. *Medical & biological engineering & computing*, 59(2) :401–415, 2021.
- [113] Tae Keun Yoo, Joon Yul Choi, Hong Kyu Kim, Ik Hee Ryu, and Jin Kuk Kim. Adopting low-shot deep learning for the detection of conjunctival melanoma using ocular surface images. *Computer Methods and Programs in Biomedicine*, 205 :106086, 2021.

- [114] Tae Keun Yoo, Ik Hee Ryu, Jin Kuk Kim, In Sik Lee, Jung Sub Kim, Hong Kyu Kim, and Joon Yul Choi. Deep learning can generate traditional retinal fundus photographs using ultra-widefield images via generative adversarial networks. *Computer Methods and Programs in Biomedicine*, 197 :105761, 2020.
- [115] Aram You, Jin Kuk Kim, Ik Hee Ryu, and Tae Keun Yoo. Application of generative adversarial networks (gan) for ophthalmology image domains : A survey. *Eye and Vision*, 9(1) :1–19, 2022.
- [116] Zekuan Yu, Qing Xiang, Jiahao Meng, Caixia Kou, Qiushi Ren, and Yanye Lu. Retinal image synthesis from multiple-landmarks input with generative adversarial networks. *Biomedical engineering online*, 18(1) :1–15, 2019.
- [117] Ziyue Zhang, Zexuan Ji, Qiang Chen, Songtao Yuan, and Wen Fan. Joint optimization of cyclegan and cnn classifier for detection and localization of retinal pathologies on color fundus photographs. *IEEE Journal of Biomedical and Health Informatics*, 26(1) :115–126, 2021.
- [118] Hanli Zhao, Xiaqing Qiu, Wanglong Lu, Hui Huang, and Xiaogang Jin. High-quality retinal vessel segmentation using generative adversarial network with a large receptive field. *International Journal of Imaging Systems and Technology*, 30(3) :828–842, 2020.
- [119] He Zhao, Huiqi Li, Sebastian Maurer-Stroh, and Li Cheng. Synthesizing retinal and neuronal images with generative adversarial nets. *Medical image analysis*, 49 :14–26, 2018.
- [120] Ce Zheng, Fang Bian, Luo Li, Xiaolin Xie, Hui Liu, Jianheng Liang, Xu Chen, Zilei Wang, Tong Qiao, Jianlong Yang, et al. Assessment of generative adversarial networks for synthetic anterior segment optical coherence tomography images in closed-angle detection. *Translational Vision Science & Technology*, 10(4) :34–34, 2021.
- [121] Ce Zheng, Xiaolin Xie, Kang Zhou, Bang Chen, Jili Chen, Haiyun Ye, Wen Li, Tong Qiao, Shenghua Gao, Jianlong Yang, et al. Assessment of generative adversarial networks model for synthetic optical coherence tomography images of retinal disorders. *Translational Vision Science & Technology*, 9(2) :29–29, 2020.
- [122] Yi Zhou, Boyang Wang, Xiaodong He, Shanshan Cui, and Ling Shao. Dr-gan : conditional generative adversarial network for fine-grained lesion synthesis on diabetic retinopathy images. *IEEE Journal of Biomedical and Health Informatics*, 2020.
- [123] Yukun Zhou, Zailiang Chen, Hailan Shen, Xianxian Zheng, Rongchang Zhao, and Xuanchu Duan. A refined equilibrium generative adversarial network for retinal vessel segmentation. *Neurocomputing*, 437 :118–130, 2021.
- [124] Jun-Yan Zhu, Taesung Park, Phillip Isola, and Alexei A Efros. Unpaired image-to-image translation using cycle-consistent adversarial networks. In *Proceedings of the IEEE international conference on computer vision*, pages 2223–2232, 2017.

RESUME

Les méthodes d'apprentissage en profondeur, et en particulier les réseaux de neurones convolutifs (CNN), ont conduit à une énorme percée dans un large éventail de tâches de vision par ordinateur. Cependant la majorité des méthodes d'analyse d'images médicales sont des méthodes supervisées, ce qui requiert une grande quantité de données étiquetées. Le nombre d'images médicales disponible est usuellement petit et son acquisition étiquetée est un processus très coûteux. C'est pourquoi, au cours de ces dernières années, le réseau antagoniste génératif (Generative Adversarial Network (GAN)) est devenu la technique de choix pour la génération et la conversion d'images dans le domaine de l'imagerie médicale. Dans ce travail, nous exploitons les GANs pour diagnostiquer une Rétinopathie Diabétique (RD), en proposant une architecture qui permet en plus d'augmenter les données à partir d'une image réelle, de la prétraiter pour améliorer sa qualité visuelle pour une meilleure classification et un bon diagnostic. Les résultats d'expérimentation obtenus sont très prometteurs.

Mots clés : Apprentissage profond ; CNN ; GAN ; image médicale ; RD ; Classification ; Augmentation de données.

ABSTRACT

Deep learning methods, and in particular convolutional neural networks (CNN), have led to a huge breakthrough in a wide range of computer vision tasks. However, the majority of medical image analysis methods are supervised methods, which require a large amount of labeled data. The number of medical images available is usually small and its labeled acquisition is a very expensive process. This is why, in recent years, the Generative Adversarial Network (GAN) has become the technique of choice for image generation and conversion in the field of medical imaging. In this work, we exploit GANs to diagnose Diabetic Retinopathy (DR), by proposing an architecture that also allows to augment the data from a real image, to preprocess it to improve its visual quality for a better classification. and a correct diagnosis. The experimental results obtained are very promising.

Key words : deep learning ; CNN ; GAN ; medical image ; DR ; Classification ; Data augmentation.