

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

MÉMOIRE PRÉSENTÉ À

L'UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

COMME EXIGENCE PARTIELLE

DE LA MAITRISE EN MATHÉMATIQUES ET INFORMATIQUE
APPLIQUÉES (M. Sc. A.)

PAR

KOFFI ADINGRA FRANCOIS BROU

RECONNAISSANCE DE L'IRIS BASÉE SUR LA COMBINAISON DES
MÉTHODES LBP ET SOM

Février 2025

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

REMERCIEMENTS

L'écrivaine Madeleine Ferron déclarait dans son œuvre le chemin des dames << Dans la vie, les hommes sont tributaires les uns des autres. Il y a donc toujours quelqu'un à maudire ou à remercier >>. C'est donc légitime pour moi de remercier toutes ces personnes qui ont œuvré de près ou de loin pour que ce mémoire voit le jour mais bien au-delà j'aimerais remercier toutes ces personnes qui m'ont aidé à réaliser ce projet d'étude ici à l'université **du QUÉBEC À TROIS-RIVIÈRES**.

Je remercie, tout d'abord les membres du jury, qui m'ont fait l'honneur de juger mon travail, ainsi que tout le corps professoral et administratif de l'université du Québec à Trois Rivières.

Je remercie Madame Oumayma Ouedrhiri et Monsieur Fadel Toure, pour leurs encadrements pédagogiques consistant, le suivi régulier de l'avancement de mon projet.

Je ne pourrai clore cette cession de remerciement sans penser à mon père monsieur Brou N'da qui a fait de mes études sa priorité pour que j'en sois là aujourd'hui. Je remercie également ma mère Yah Pauline et mon épouse Marie Marthe.

RÉSUMÉ

L'usurpation d'identité est devenue un fléau majeur à l'ère du numérique. Elle se caractérise par le fait qu'un individu se fait passer pour quelqu'un d'autre en utilisant des informations personnelles volées ou falsifiées. Cette pratique malveillante entraîne des conséquences dévastatrices dans de nombreux secteurs d'activité. Les banques et les institutions financières sont particulièrement touchées par ces fraudes d'identité. Pour remédier à ce fléau les chercheurs ne cessent d'innover afin de créer des systèmes d'identification plus sécuritaires d'où, l'introduction de la sécurité biométrique par l'iris humain qui est une des techniques d'identification les plus sûres au monde [1]. Cependant, les techniques traditionnelles de la biométrie par l'iris ont leurs limites qui peuvent être au niveau de la segmentation, la normalisation de la texture de l'iris ou même de la classification.

Pour pallier ces problèmes, ce mémoire propose un système d'identification par l'iris avec une approche basée sur la méthode des motifs binaires locaux (LBP) et les carte auto-organisatrices (SOM).

La méthode LBP se concentre sur l'extraction des caractéristiques texturales locales tandis que les réseaux de neurones (SOM) [2] sont excellents pour la classification. En combinant les deux, on a pu capturer à la fois des informations globales et locales, améliorant ainsi la robustesse du modèle avec une précision de **99.00%** de reconnaissance et une rapidité de reconnaissance de **0.01 seconde**. Les résultats obtenus montrent que la combinaison de la méthode LBP et des réseaux SOM est une approche prometteuse.

Mots clé: Motif local binaire (LBP ou Local Binary Pattern); Carte auto-Organisatrice (Self-Organizing Map ou SOM); Reconnaissance de l'iris.

ABSTRACT

Identity theft has become a major scourge in the digital age. It is characterized by an individual impersonating someone else using stolen or falsified personal information. This malicious practice has devastating consequences in many sectors. Banks and financial institutions are particularly affected by these identity frauds. To combat this scourge, thinkers and researchers continually innovate to create more secure identification systems, leading to the introduction of biometric security through human iris recognition, one of the most secure identification techniques in the world [1]. However, traditional iris biometrics techniques have their limitations, which can be faced in segmentation, texture normalization of the iris, or even in classification. To address these issues, this thesis proposes an iris identification system based on the Local Binary Patterns (LBP) method and Self-Organizing Maps (SOM). The LBP method focuses on extracting local textural features, while SOM neural networks [2] excel in classification. By combining both, we were able to capture global and local information, thereby improving the robustness of the model, achieving a recognition accuracy of 99.00% and a recognition speed of 0.01 seconds. The retrieved results demonstrate that the combination of the LBP method and SOM is a promising approach

TABLE DES MATIÈRES**Page**

REMERCIEMENTS.....	II
RÉSUMÉ	III
ABSTRACT.....	IV
INTRODUCTION	1
CHAPITRE 1 : CONCEPTS ET DEFINITIONS.....	1
1.1 Historique.....	1
1.2 Les techniques biométriques.....	2
1.3 Système de reconnaissance de l’iris.....	4
1.4 L’iris.....	Erreur! Signet non défini.
1.5 L’acquisition	6
1.6 Prétraitement	7
1.6.1 La segmentation	8
1.6.2 Normalisation (La méthode pseudo polaire).....	9
1.7 Extraction des caractéristiques (LBP).....	12
1.8 Classification.....	13
1.9 Les réseaux de neurones	14
1.9.1 Perceptron multicouche (MLP).....	19
1.9.2 Réseaux de neurones convolutifs (CNN).....	21
1.9.3 Modèle de Kohonen (SOM).....	22
Conclusion	24
CHAPITRE 2 : REVUE DE LITTÉRATURE	25
Introduction.....	25
2.1 Méthodes traditionnelles de reconnaissance de l’iris.....	25
2.2 Méthodes basées sur les réseaux de neurones.....	31

2.3	Approches basées sur les LBP et hybride	34
	Conclusion	40
	CHAPITRE 3 : ARCHITECTURE PROPOSÉE	41
	Introduction.....	41
3.1	Prétraitement	41
3.2	Extraction des caractéristiques (LBP).....	44
3.3	Classification.....	45
3.3.1	Composition et principe.....	45
3.3.2	Modèle d'apprentissage	45
	Conclusion	46
	CHAPITRE 4 : IMPLEMENTATION ET RESUTATS	48
	Introduction.....	48
4.1	Outils & environnement.....	48
4.2	Base de données utilisée	49
4.3	Prétraitement	51
4.4	Extraction des caractéristiques (LBP).....	54
4.5	Entraînement du modèle (SOM).....	55
4.6	Résultats.....	61
4.7	Discussion	65
	Conclusion	66
	CONCLUSION GENERALE.....	67
	RÉFÉRENCES BIBLIOGRAPHIQUES.....	69

LISTE DES TABLEAUX

Page

Tableau 2.1: Tableau récapitulatif d'autres études portant sur le domaine de la biométrie	39
Tableau 4.1 : Extrait des caractéristiques de certaines images à l'aide de la méthode LBP	55
Tableau 4.2 : Tableau de progression de l'entraînement du modèle.	55
Tableau 4.3 : Tableau de l'algorithme d'entraînement.	55
Tableau 4.4 : Historique des graphiques d'entraînement.	56
Tableau 4.5 : Résumé des performances d'identification et des échantillons utilisés.	61

LISTE DES FIGURES

Page

Figure 1.1: Illustration des différentes étapes d'un système biométrique de l'iris (réf: auteur du mémoire).	5
Figure 1.2: Anatomie de l'œil humain [15]	6
Figure 1.3: Image de l'iris acquise en lumière visible [16]	7
Figure 1.4: Le modèle de Daugman Rubber Sheet [20].	11
Figure 1.5 Architecture d'un réseau de neurone multicouche [25]	19
Figure 1.6: Architecture d'un réseau de neurones artificiels MLP [31].	20
Figure 1.7 : Architecture d'un réseau de neurone CNN [33].....	22
Figure 1.8: Architecture des cartes auto-organisatrices (SOM) [35].....	23
Figure 3.1: (a) région de l'iris, (b) localisation de la pupille et de l'iris [54].	43
Figure 3.2: Segmentation de l'Iris par la méthode intégrro-differentielle. [55]	44
Figure 3.3: Exemple d'un code de l'iris extrait par l'opérateur LBP [43].....	45
Figure 4.1: Graphique illustrant le nombre de publications utilisant la base de données CASIA-Iris par année, de 2004 à 2023.....	50
Figure 4.2: Image tirée de la base de données CASIA-IrisvV4 [16]	51
Figure 4.3 : Image en niveaux de gris d'un iris de Casia-irisV1	52
Figure 4.4: Détection des contours	53
Figure 4.5: code de l'iris normalisé (base de données CASIA-IrisV1)	53
Figure 4.6 : Graphique de l'extraction des caractéristiques par la méthode LBP.....	54
Figure 4.7 : Topologie de la carte auto-organisatrice (SOM).....	57

Figure 4.8 : Connexion de voisinage	Figure 4.9 : positions des poids des neurones...	58
Figure 4.10 : Distances de poids entre les neurones		59
Figure 4.11 : SOM Hits.....		60
Figure 4.12 : Interface utilisateur de notre système.....		62

INTRODUCTION

De nos jours, la sécurité électronique est confrontée à un besoin critique de trouver des alternatives fiables et efficaces aux mots de passe et aux numéros d'identification personnels (PIN). Les pertes financières annuelles augmentent considérablement en raison de la fraude informatique, de l'accès frauduleux aux ordinateurs et du vol d'identité[3].

Dans l'optique de trouver des solutions à tous ces travers, nous nous sommes tournés vers les solutions biométriques qui abordent les problèmes fondamentaux de reconnaissance des individus en se basant sur leurs caractéristiques morphologiques ou comportementales, d'où l'introduction de la biométrie de l'iris humain. La reconnaissance de l'iris est cruciale en biométrie car elle permet d'identifier les individus avec une grande précision grâce aux caractéristiques uniques de leur iris [4].

L'œil humain est un organe essentiel pour notre perception du monde. Il nous permet de voir les couleurs, les formes et les mouvements, et il est directement relié à notre cerveau. L'iris est la partie colorée de l'œil, située entre le blanc de l'œil (la sclère) et la pupille. Sa couleur varie d'une personne à l'autre (bleu, vert, marron, etc.) en fonction de la quantité de mélanine présente. La reconnaissance de l'iris pour l'identification des individus a été proposée dès 1936, mais c'est dans les années 1980 que cette idée a ressurgi. Aujourd'hui, les algorithmes basés sur les ondes de Gabo, brevetés par John Daugman en 1994, servent de base à tous les systèmes d'identification par l'iris [5].

1. Motivation

La sécurité et la confidentialité des informations personnelles sont devenues des préoccupations majeures dans notre société de plus en plus numérique. Les systèmes de reconnaissance biométrique, et plus particulièrement la reconnaissance de l'iris, sont largement utilisés pour sécuriser l'accès aux dispositifs électroniques, aux systèmes d'information et aux infrastructures critiques. Cependant, les méthodes traditionnelles de reconnaissance de l'iris peuvent être sensibles aux variations environnementales et aux transformations géométriques, ce qui peut entraîner des taux d'erreur plus élevés.

L'utilisation des réseaux de neurones, et en particulier des réseaux de neurones profonds, a montré des performances remarquables dans diverses applications de reconnaissance d'images et de modèles, grâce à leur capacité à apprendre des caractéristiques discriminantes à partir de données complexes et non linéaires. En intégrant la méthode Local Binary Patterns (LBP), qui est efficace pour extraire des caractéristiques locales texturales, il est possible de concevoir un système hybride qui combine la robustesse des descripteurs LBP et la puissance de généralisation des réseaux de neurones SOM.

Cette étude vise donc à explorer et à développer une approche qui tire parti des capacités des LBP et de l'apprentissage profond pour améliorer la précision et la robustesse de la reconnaissance de l'iris.

2. Objectifs

Ce mémoire propose un système de reconnaissance de l'iris. Notre principal défi consiste donc à élaborer une méthodologie, à concevoir et à mettre en œuvre un système qui garantisse une grande précision et une rapidité d'exécution. Pour ce faire, nous explorerons une approche basée sur une combinaison de deux méthodes, à savoir les motifs locaux binaires (LBP) et les réseaux de neurones (SOM), ce qui selon nous, pourrait améliorer l'efficacité et l'exactitude de notre système.

Les objectifs spécifiques incluent :

1. **Améliorer la précision** : Renforcer la capacité du système à identifier les caractéristiques correctes avec une grande exactitude, en réduisant les erreurs de détection et en augmentant le taux de réussite global.
2. **Assurer une robustesse aux variations** : Assurer une reconnaissance fiable malgré les variations de luminosité, de position et d'angle.
3. **Efficacité computationnelle** : Optimiser les algorithmes pour une exécution rapide et efficace, adaptée aux systèmes en temps réel.

En répondant à ces défis, cette étude pourrait non seulement améliorer la performance des systèmes de reconnaissance de l'iris actuels, mais aussi ouvrir la voie à des nouvelles applications dans des domaines nécessitant une sécurité biométrique avancée, tels que la protection des données sensibles, l'identification sécurisée des individus et les systèmes de contrôle d'accès.

3. Organisation du mémoire

Dans ce travail, nous commençons par présenter des informations générales sur la technologie biométrique et ses applications dans divers domaines de la vie quotidienne au **chapitre 1**. Le **chapitre 2** est consacré à une analyse bibliographique des différentes approches en biométrie, avec une revue des résultats obtenus dans chaque étude. Nous examinons d'abord les méthodes traditionnelles de reconnaissance, qui reposent souvent sur des techniques statistiques ou géométriques pour identifier les caractéristiques biométriques. Ensuite, nous analysons les méthodes basées sur les réseaux de neurones, qui révolutionnent le domaine en offrant des capacités d'apprentissage profond pour extraire automatiquement des caractéristiques complexes à partir des données biométriques. Enfin, nous nous penchons sur l'approche basée sur les Local Binary Patterns (LBP) et hybride, une méthode efficace pour capturer les motifs texturaux uniques des caractéristiques biométriques, souvent utilisée pour la reconnaissance d'iris et d'empreintes digitales.

Le **chapitre 3** détaille les principales étapes de notre architecture, incluant le traitement, la segmentation, la normalisation, l'extraction des caractéristiques et la reconnaissance. Enfin, dans le **dernier chapitre**, nous présentons notre système construit et les résultats obtenus à partir des expérimentations, ainsi que les différentes étapes qui accompagnent leur mise en œuvre.

CHAPITRE 1 : CONCEPTS ET DEFINITIONS

1.1 Historique

L'utilisation des caractéristiques biométriques pour l'identification des personnes remonte à l'Antiquité, où les empreintes digitales étaient utilisées comme signatures ou sceaux. Au Moyen Âge, les portraits étaient utilisés pour reconnaître les souverains ou les nobles. À la Renaissance, les artistes ont développé la technique du portrait-robot, qui consistait à assembler des traits du visage à partir de descriptions verbales.

Au XIXe siècle, la photographie et l'anthropométrie ont permis de créer des fichiers d'identité pour les criminels ou les immigrants. Au XXe siècle [6], les progrès de la génétique et de l'informatique ont permis de développer de nouvelles techniques biométriques, comme la reconnaissance de l'ADN, de l'iris, de la voix ou de la signature. Au XXIe siècle, la biométrie est devenue un outil courant pour la sécurité, le contrôle d'accès, le commerce ou le divertissement.

La biométrie peut être utilisée pour remplacer ou renforcer la sécurité des mots de passe, des codes PIN, des cartes d'accès ou des clés [6]. La biométrie peut également être utilisée pour protéger les documents sensibles, les transactions financières, les passeports électroniques ou les contrôles aux frontières. Aujourd'hui, il existe plusieurs systèmes biométriques. Un système biométrique [7] est un dispositif qui utilise des caractéristiques pour vérifier l'identité d'une personne ou lui donner accès à un service ou à une ressource. Par exemple, nos téléphones qui se déverrouillent en scannant nos visages ou notre doigt. Il existe différents types de systèmes biométriques, selon les caractéristiques utilisées et les méthodes employées.

Certains systèmes biométriques sont basés sur l'analyse morphologique, comme les empreintes digitales, l'iris ou le visage. D'autres sont basés sur l'analyse biologique, comme l'ADN ou les odeurs corporelles. D'autres encore sont basés sur l'analyse comportementale, comme la voix, la signature ou la démarche. Certains systèmes biométriques combinent plusieurs de ces aspects pour renforcer la sécurité ou la fiabilité.

La biométrie présente des avantages et des inconvénients, notamment en termes de protection de la vie privée, de sécurité et de performance. Concernant les avantages, on peut citer

la fiabilité, la rapidité, la non-répudiation et la réduction des coûts. Comme inconvénients, nous avons les risques de fraude, de piratage, de vol d'identité, de violation de la vie privée, de discrimination ou de rejet.

1.2 Les techniques biométriques

Les techniques biométriques sont des méthodes qui permettent de reconnaître de façon automatique un individu en se basant sur ses Caractéristiques physiques, biologiques ou comportementales. Voici quelques exemples courants de techniques biométriques :

- Reconnaissance des empreintes digitales [8][9]: Cette technique utilise les motifs uniques formés par les crêtes et les vallées de la peau au bout des doigts. Elle est largement utilisée pour le contrôle d'accès, l'authentification et la vérification d'identité. Un capteur scanne l'empreinte digitale et la compare à une base de données pré-enregistrée.
- Reconnaissance faciale [10]: Elle utilise les caractéristiques du visage telles que la forme, la taille, la position et la couleur des yeux, du nez, des lèvres et des sourcils. Elle est utilisée pour la surveillance, le déverrouillage des appareils et les paiements. Une caméra capture l'image du visage et la compare à une base de données pré-enregistrée.
- Reconnaissance de l'iris[11]: Cette technique repose sur les motifs uniques formés par les fibres musculaires de l'iris, la partie colorée de l'œil. Elle est considérée comme l'une des méthodes biométriques les plus précises et fiables, utilisée pour le contrôle d'accès et la vérification d'identité. Un capteur scanne l'iris et le compare à une base de données préenregistrée.
- Reconnaissance vocale [12]: Elle se base sur les caractéristiques de la voix telles que le timbre, le ton, le rythme et l'accent. Utilisée pour l'authentification, la commande vocale et la transcription. Un microphone enregistre la voix et la compare à une base de données préenregistrée.

Reconnaissance de la signature [13]: La reconnaissance de la signature est une technique biométrique qui authentifie l'identité d'une personne en analysant les caractéristiques uniques de sa signature manuscrite. Ce processus peut inclure la capture de la signature sur une tablette ou un

capteur spécial, puis l'examen de divers éléments tels que la pression du stylo, la vitesse et la dynamique du mouvement, ainsi que la forme et la taille des lettres. Cette méthode est souvent utilisée dans des contextes où la vérification de l'identité est essentielle, comme les transactions bancaires, les documents légaux et les accès sécurisés. En résumé, les techniques biométriques offrent des méthodes précises et fiables pour identifier et authentifier les individus.

1.3 Système de reconnaissance de l'iris

La reconnaissance de l'iris présente plusieurs avantages par rapport à d'autres techniques biométriques, comme les empreintes digitales ou la reconnaissance faciale. Elle est plus précise, plus rapide, plus fiable et plus sécurisée [14]. Elle est également moins sensible aux variations de l'environnement, comme l'éclairage, l'angle de vue, les expressions faciales ou les accessoires. Elle est aussi plus respectueuse de la vie privée, car elle ne nécessite pas de contact physique avec le capteur, et elle ne peut pas être facilement falsifiée ou volée [4].

Elle est utilisée dans de nombreux domaines comme la sécurité, le contrôle d'accès, le commerce, le divertissement ou la santé. Par exemple, elle permet de déverrouiller un smartphone, de passer les douanes, de payer avec son regard, de jouer à un jeu vidéo ou de diagnostiquer des maladies. Il faut noter que le processus de reconnaissance de l'iris comprend 5 étapes principales à savoir (Figure 1.1):

- Acquérir l'image de l'œil d'une personne au moment de l'inscription
- Segmenter l'iris de l'image contenant l'œil et une partie du visage pour localiser le motif de l'iris
- Normaliser le motif de l'iris en l'extrayant et en le mettant à l'échelle à une taille prédéfinie
- Encoder ou extraire les caractéristiques, en filtrant et en représentant les détails de l'iris dans un code d'iris
- Classifier les données en attribuant une étiquette ou une catégorie à chaque instance basée sur ses caractéristiques ou attributs.

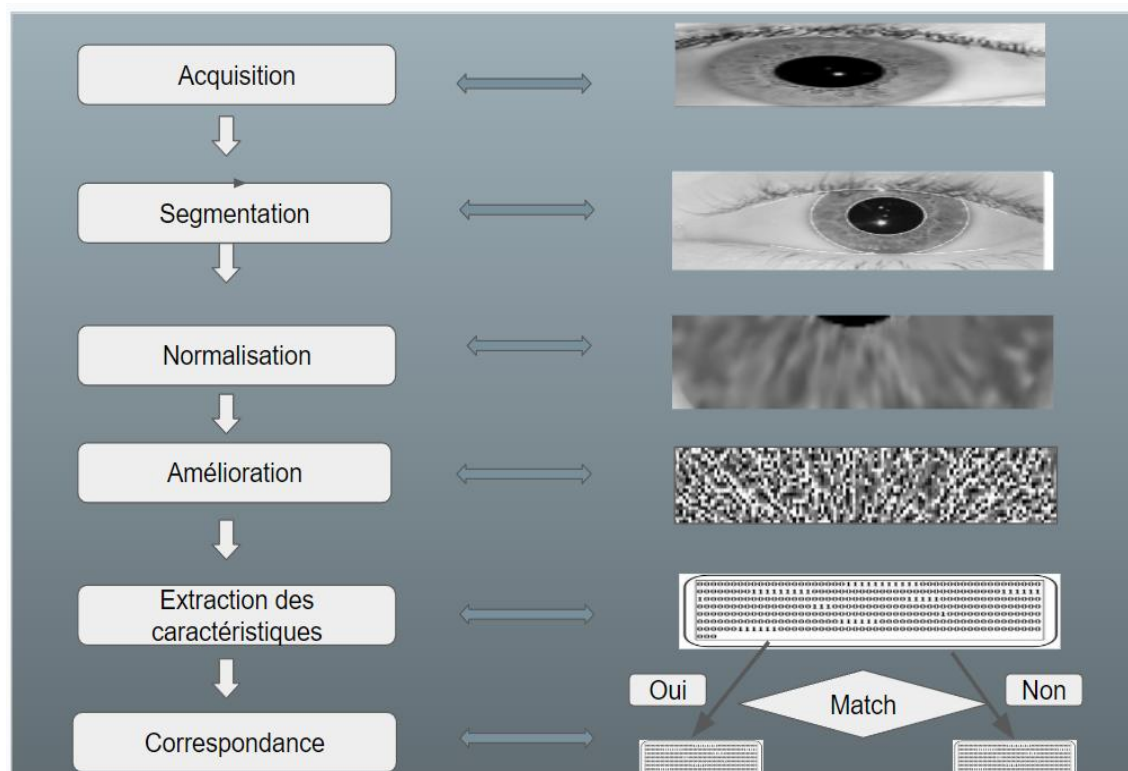


Figure 1.2: Illustration des différentes étapes d'un système biométrique de l'iris.

L'iris humain est la partie colorée de l'œil qui contrôle la quantité de lumière qui entre dans la pupille. La couleur de l'iris varie selon la concentration en mélanine, un pigment brun. Il existe plusieurs nuances de couleur d'iris, allant du noir au bleu, en passant par le marron, le vert ou le noisette. Il est composé de deux muscles qui permettent de dilater ou de contracter la pupille en fonction de la luminosité ambiante. L'iris peut être affecté par certaines maladies ou anomalies, comme l'antiride, l'albinisme oculaire ou l'hétérochromie.

L'iris est constitué d'un certain nombre de couches que sont (voir figure 1.2):

- La plus basse est la couche de l'épithélium, qui contient des cellules pigmentaires denses, la mélanine, responsable de la couleur de l'iris.
- La couche stromale se situe au-dessus de la couche de l'épithélium, et contient des vaisseaux sanguins, des cellules pigmentaires et de deux muscles de l'iris.

Ces deux muscles, le dilatateur et le muscle du sphincter, contrôlent la contraction et la dilatation de l'iris pour régler la quantité de lumière entrant dans la pupille vers la rétine. La surface externe multicouche de l'iris est constituée de deux régions, qui diffèrent souvent de couleur, la zone centrale pupillaire et la zone extérieure ciliaire.




Figure 1.3: Anatomie de l'œil humain [15]

1.4 L'acquisition

L'acquisition d'une image de l'iris humain est une étape importante du processus de la mise en œuvre d'un système de reconnaissance biométrique de l'iris. Pour capturer une image de l'iris, il faut utiliser une caméra spéciale, qui émet une lumière infrarouge invisible pour l'œil humain (voir figure 1.3). Cette lumière permet de révéler les détails de l'iris, tout en évitant les reflets de la cornée. La caméra doit être placée à une distance suffisante pour ne pas gêner la personne, mais assez proche pour obtenir une image nette et précise. Elle doit également être alignée avec le centre de l'œil, et la personne doit regarder droit devant elle. L'image de l'iris doit être de bonne qualité, sans flou, sans ombre, sans obstruction, sans distorsion ni bruit. Elle doit aussi couvrir une grande

partie de l'iris, sans être coupée par la paupière ou les cils. Une fois l'image de l'iris acquise, elle peut être traitée par un algorithme qui extrait les caractéristiques de l'iris et les transforme en un code numérique, qui représente l'identité de la personne.




Figure 1.4: Image de l'iris acquise en lumière visible [16]

1.5 Prétraitement

Le prétraitement des images, en particulier pour les applications biométriques telles que la reconnaissance de l'iris, est une étape qui permet de garantir des performances élevées dans les étapes ultérieures de traitement et de reconnaissance.

Les fonctions de prétraitement englobent les opérations nécessaires avant l'analyse principale et l'extraction des informations. Ces opérations se divisent en deux catégories que sont les corrections radiométriques et les corrections géométriques.

- Les corrections radiométriques incluent, entre autres, l'ajustement des données pour compenser les irrégularités, la réduction du bruit provenant du capteur ou de l'atmosphère, et la conversion des données afin qu'elles

reflètent avec précision le rayonnement réfléchi ou émis mesuré par le capteur.

- Les corrections géométriques visent à aligner et à normaliser les images afin que les caractéristiques extraites soient comparables et que les variations non pertinentes soient minimisées.

1.5.1 La segmentation

La segmentation permet de déterminer le contour de l'iris, ainsi que le centre et le rayon de la pupille [17]. Elle est essentielle pour la qualité et la fiabilité de la reconnaissance de l'iris, car elle influe sur les étapes suivantes, comme la normalisation, l'extraction des caractéristiques et la comparaison des codes iriens.

La segmentation de l'iris humain peut être réalisée par différentes méthodes, qui utilisent des algorithmes basés sur des approches mathématiques ou géométriques. Par exemple, certaines méthodes utilisent la détection des contours, la transformée de Hough, le modèle actif de contours, les ondelettes, les réseaux de neurones ou les techniques d'apprentissage automatique. Ces méthodes visent à trouver les paramètres qui définissent le cercle de l'iris et le cercle de la pupille, en minimisant l'erreur entre les pixels de l'image et les pixels du modèle. Certaines méthodes prennent également en compte la déformation de l'iris causée par la dilatation ou la contraction de la pupille, ou par le changement d'angle de vue.

La segmentation de l'iris humain est un domaine de recherche actif, qui vise à améliorer la performance, la robustesse et la rapidité des algorithmes, face aux défis posés par les variations de l'iris, les conditions d'acquisition, les facteurs environnementaux ou les contraintes de sécurité [17].

La transformation de Hough a été initialement introduite par Hough pour détecter des alignements de points[18]. Plus généralement, à la suite des travaux de Duda et Hart [19], on désigne par transformation de Hough une méthode permettant de repérer une forme géométrique dans une

image. Cette méthode a fait l'objet d'un nombre important de travaux, aussi bien du point de vue théorique, du point de vue de sa formulation, que d'un point de vue industriel pour ses applications en reconnaissance de forme.

1.5.2 Normalisation (La méthode pseudo polaire)

La normalisation est une étape qui consiste à transformer l'image de l'iris en une forme standardisée et comparable. Il existe différentes méthodes de normalisation de l'image de l'iris, mais l'une des plus courantes est la méthode de Daugman, qui utilise un modèle de caoutchouc pour déformer l'anneau de l'iris en un rectangle. Cette méthode permet de compenser les variations de taille, de forme et de position de l'iris dues à la distance, à l'angle de vue, à la dilatation pupillaire ou à l'expression faciale [7].

La méthode de Daugman consiste en plusieurs étapes que sont :

- La localisation de l'iris, qui consiste à détecter le centre et le rayon de la pupille et de l'iris, ainsi que les éventuelles paupières ou cils qui occultent l'iris. Cette étape peut être réalisée par diverses techniques, comme la transformée de Hough circulaire, la détection de contours ou l'analyse de la luminosité.

La transformation polaire, qui consiste à cartographier chaque pixel de l'anneau de l'iris sur un système de coordonnées polaires, défini par un angle σ et un rayon r . Cette transformation permet de passer d'une image circulaire à une image rectangulaire, dont la largeur correspond à la longueur du contour de l'iris et la hauteur correspond à la différence entre les rayons de l'iris et de la pupille. La normalisation de l'intensité, qui consiste à ajuster la luminosité et le contraste de l'image rectangulaire, afin de réduire les effets de l'éclairage, de la réflexion ou du bruit. Cette étape peut être réalisée par diverses techniques, comme l'égalisation d'histogramme, la normalisation zéro-moyenne ou la normalisation min-max.

La normalisation de l'image de l'iris permet de faciliter l'extraction des caractéristiques distinctives de l'iris, qui seront ensuite utilisées pour la comparaison et l'identification des individus. La

normalisation de l'image de l'iris est donc une étape cruciale pour assurer la fiabilité et la performance du système de reconnaissance de l'iris.

La méthode pseudo polaire est une technique de normalisation des images d'iris proposée par John Daugman[7]. Elle consiste à transformer les coordonnées cartésiennes d'une image en coordonnées polaires, en utilisant un système de référence centré sur la pupille de l'œil. Ainsi, chaque pixel de l'image est représenté par un angle et un rayon, qui correspondent respectivement à la position angulaire et à la distance par rapport au centre de la pupille (Voir figure 1.4).

Elle permet de réduire les effets de la dilatation et de la contraction de la pupille, ainsi que de l'occlusion partielle de l'iris par les paupières ou les cils. Elle permet également de comparer facilement les images d'iris de différentes personnes, en utilisant des mesures de similarité basées sur les caractéristiques locales de l'iris.

Elle est souvent utilisée en combinaison avec la transformée de Hough circulaire, qui permet de détecter les contours de la pupille et de l'iris dans une image. La transformée de Hough cherche les cercles présents dans une image, en utilisant un espace de paramètres constitué du rayon et du centre du cercle [7]. Pour chaque pixel de l'image, on calcule les cercles possibles qui passent par ce pixel, et on vote pour les paramètres correspondants dans l'espace de Hough. Les paramètres qui reçoivent le plus de votes sont considérés comme les meilleurs candidats pour représenter les cercles recherchés.




Figure 1.5: Le modèle de Daugman Rubber Sheet [20].

Le procédé peut être expliqué de la manière suivante : A chaque pixel de l'Iris dans le domaine cartésien est assigné un correspondant dans le domaine pseudo polaire suivant la distance du pixel par rapport aux centres des cercles et l'angle qu'il fait avec ces centres.

$$x = p \cos(\theta) - a$$

$$y = p \sin(\theta) - b$$

Où (a, b) est le centre du cercle en p et θ sont les coordonnées pseudo-polaire.

1.6 Extraction des caractéristiques (LBP)

Le motif binaire local [21] (ou **Local Binary Pattern**) est une caractéristique utilisée en vision par ordinateur pour reconnaître des textures ou pour la détection d'objet dans des images numériques. Le principe général est de comparer le niveau de luminance d'un pixel avec les niveaux de ses voisins. Cela reflète donc des informations concernant des motifs réguliers dans l'image, autrement dit, une texture. Selon l'échelle de voisinage utilisée, certaines zones d'intérêt, telles que des coins ou des bords, peuvent être détectées par ce descripteur [21].

Pour calculer un motif binaire local, une texture est définie dans le voisinage de rayon d'une image (en niveaux de gris) comme la distribution jointe de pixels. Ce vecteur de dimension P reflète les différences locales de niveau de gris. Afin de renforcer l'invariance à des changements monotones des niveaux de gris, seul le signe de ces différences est pris en compte [21].

Il ne reste alors qu'à pondérer chaque différence avec un facteur de la forme pour obtenir un code unique, aboutissant au descripteur du motif binaire local en un point. Pour une image comportant N pixels, ce motif est calculé en chaque point faisant sens, ce qui résulte en un descripteur global décrivant la texture de l'image [21].

Principe : Les modèles binaires locaux sont calculés dans leur image la plus simple de l'image de texture, comme suit :

Sélectionner d'abord le système adjacent et le nombre de points adjacents (par exemple, 3x3 et 8 points adjacents au point central).

- Comparer chacun des points adjacents (huit points) au point central. Si le point central est plus grand, stocker la valeur 0 dans un vecteur, sinon, stocker la valeur 1.

Ce dernier produit un vecteur par pixel dans l'image constitué de huit éléments binaires convertis en un nombre décimal, de sorte que chaque pixel de l'image a un nombre décimal.

Un histogramme est ensuite créé pour toutes les valeurs décimales de l'image utilisée.

En résumé, la formule LBP pour un pixel central dans un voisinage circulaire est :

$$LBP = \sum_{i=0}^{P-1} (f(p_i - p_c) \cdot 2^i)$$

1.7 Classification

La classification est un processus de catégorisation, qui consiste à reconnaître, différencier et comprendre des idées et des objets [22]. Elle est définie comme l'acte ou le processus de regroupement de faits connexes en classes. Elle peut également se référer à un processus qui rassemble des choses similaires et sépare des choses différentes. Il existe plusieurs techniques.

Le cosinus de similarité est une mesure de similarité entre deux vecteurs non nuls dans un espace de produit intérieur. Elle est fréquemment utilisée dans la recherche d'informations et l'exploration de textes pour identifier le degré de similitude entre deux documents [23], [24].

Le cosinus de similarité est le cosinus de l'angle entre les vecteurs. C'est-à-dire, c'est le produit scalaire des vecteurs divisé par le produit de leurs longueurs. Il en résulte que le cosinus de similarité ne dépend pas des magnitudes des vecteurs, mais seulement de leur angle.

Le cosinus de similarité appartient toujours à l'intervalle [-1,1]. Par exemple, deux vecteurs proportionnels ont une similarité de 1, deux vecteurs orthogonaux ont une similarité de 0, et deux vecteurs opposés ont une similarité de -1.

Dans certains contextes, les valeurs des composantes des vecteurs ne peuvent pas être négatives, auquel cas le cosinus de similarité est bornée dans [0,1]. Par exemple, en recherche d'information et en fouille de textes, chaque mot se voit attribuer une coordonnée différente et un document est représenté par le vecteur des nombres d'occurrences de chaque mot dans le document. Le cosinus de similarité donne alors une mesure utile de la similarité probable de deux documents en termes de sujet, indépendamment de la longueur des documents [23], [24].

La formule mathématique pour calculer le cosinus de similarité entre deux vecteurs A et B est la suivante :

$$d(a, b) = 1 - \frac{A}{||A||} \frac{B}{||B||}$$

Où A et B sont deux vecteurs caractérisant deux iris et $(||. ||)$ indique la norme euclidienne.

$$\text{Avec } 0 \leq \frac{A}{||A||} \frac{B}{||B||} \leq 1$$

La distance euclidienne est une mesure de la distance entre deux points dans un espace euclidien. Elle est souvent utilisée dans divers domaines tels que la géométrie, l'algèbre linéaire, la science des données et le traitement de l'image. Entre deux points elle peut être calculée à partir des coordonnées cartésiennes des points en utilisant le théorème de Pythagore. Par conséquent, elle est parfois appelée la distance pythagoricienne [24].

La distance Euclidienne donne une mesure du degré de similarité entre deux modèles selon la formule suivante :

$$ED = \sqrt{\sum_{i=1}^N (a_i - b_i)^2}$$

Où a, b représente les deux modèles d'iris et N est la taille du modèle d'iris.

1.8 Les réseaux de neurones

Les réseaux de neurones[25], également connus sous le nom de réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés (SNN), constituent un sous-ensemble de l'apprentissage automatique et sont au cœur des algorithmes de l'apprentissage profond. Leur nom et leur structure sont inspirés du cerveau biologique, imitant la manière dont les neurones biologiques s'envoient des signaux. Leur développement et leur mise en œuvre ont révolutionné de nombreux domaines de l'intelligence artificielle, grâce à leur capacité à apprendre et à généraliser à partir de données complexes.

Les réseaux de neurones artificiels (ANN) sont constitués de plusieurs couches de nœuds, également appelés neurones ou unités de traitement (voir figure 1.5). Ces couches comprennent :

- Une couche d'entrée qui reçoit directement les données brutes
- Une ou plusieurs couches cachées, souvent nombreuses dans les réseaux de neurones profonds, capturant des représentations hiérarchiques des données
- Une couche de sortie qui produit la réponse finale du réseau, que ce soit une classification, une régression ou une autre forme de prédiction

La formule mathématique pour la sortie y d'un neurone est donnée par :

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right)$$

Où:

x_i est l'entrée i

w_i est le poids associé à l'entrée i

b est le biais

f est la fonction d'activation, par exemple, la fonction sigmoïde, ReLu, ou tanh

Chaque neurone dans ces couches est connecté à d'autres neurones via des connexions pondérées[26]. Ces poids sont des paramètres ajustables qui déterminent l'influence d'un neurone sur un autre. En plus des poids, chaque neurone a un biais, un autre paramètre ajustable qui permet au neurone de moduler son seuil d'activation. Lorsque les entrées d'un neurone, pondérées par leurs poids respectifs, sont additionnées et dépassent un certain seuil (le biais), le neurone est activé et envoie un signal à la couche suivante. Ce mécanisme d'activation est souvent modélisé par une fonction non linéaire, qui permet au réseau de modéliser des relations non linéaires complexes entre les données d'entrée et les sorties.

Quelques fonctions d'activations couramment utilisées sont :

- **Fonction Sigmoidale** : est une fonction d'activation couramment utilisée dans les réseaux de neurones. Elle transforme une valeur d'entrée en une valeur de sortie dans une plage de 0 à 1. Et se traduit par la formule suivante :

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

- **Fonction Tanh (tangente hyperbolique)**: est une autre fonction d'activation. Elle transforme une valeur d'entrée en une valeur de sortie dans la plage de -1 à 1.

$$f(z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

- **Fonction ReLu (Rectified Linear Unit)** : est une fonction d'activation dans les réseaux de neurones profonds. Elle retourne 0 pour toutes les valeurs d'entrée négatives et retourne la valeur d'entrée elle-même pour toutes les valeurs positives. Ainsi, la sortie est dans l'intervalle $[0, +\infty)$

$$\text{ReLu}(z) = \max(0, z)$$

Les réseaux de neurones [27] s'appuient sur des données d'entraînement pour apprendre et améliorer leur précision progressivement au fil des époques. Le processus d'apprentissage implique l'ajustement des poids et des biais pour minimiser l'erreur entre les prédictions du réseau et les valeurs réelles. Cette optimisation est généralement réalisée par un algorithme appelé rétropropagation, qui utilise la descente de gradient pour mettre à jour les poids. La rétropropagation fonctionne en calculant l'erreur dans la sortie du réseau, puis en propageant sa dérivée (la dérivée de l'erreur), en ajustant les poids à chaque étape pour réduire cette erreur.

- **Forward Propagation**

$$a_j^{(l)} = f\left(\sum_{i=1}^n w_{ij}^{(l)} a_i^{(l-1)} + b_j^{(l)}\right)$$

ou $a_i^{(l-1)}$ est la sortie du neurone i de la couche précédente ($l - 1$)

$F(.)$: Fonction d'activation (ex: ReLU, Sigmoid, Tanh).

N : Nombre de neurones dans la couche précédente ($l-1$).

$W_{ij}(l)$: Poids reliant le neurone i de la couche précédente ($l-1$) au neurone j de la couche actuelle (l).

$a_i^{(l-1)}$: Activation (ou sortie) du neurone i dans la couche précédente ($l-1$).

$b_j(l)$: Biais ajouté au neurone j dans la couche l .

Interprétation : Cette équation décrit comment la sortie d'un neurone dans la couche l est calculée en combinant les sorties des neurones de la couche précédente ($l-1$), pondérées par des poids w_{ij} avec un biais b_j avant d'appliquer une fonction d'activation.

- **Erreur et Fonction Coût**

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m (h_W(x^{(i)}) - y^{(i)})^2$$

Où :

$J(W, b)$: Fonction coût qui mesure l'erreur entre les prédictions du modèle et les vraies valeurs.

m est le nombre d'exemple d'entraînement

$h_W(x^{(i)})$ est la sortie prédite pour l'exemple i

$y^{(i)}$ est la vraie valeur pour l'exemple i

$(h_W(x^{(i)}) - y^{(i)})^2$: Erreur quadratique entre la prédiction et la vraie valeur.

Interprétation : Cette fonction coût correspond à **l'erreur quadratique moyenne (MSE - Mean Squared Error)**. Elle sert à mesurer à quel point les prédictions du modèle s'écartent des vraies valeurs. L'objectif de l'entraînement est de minimiser cette fonction en ajustant les poids W et les biais b

- **Rétropropagation (Backpropagation)**

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial J}{\partial w_{ij}}$$

$$b_j \leftarrow b_j - \eta \frac{\partial J}{\partial b_j}$$

w_{ij} : Poids de la connexion entre le neurone i de la couche précédente et le neurone j de la couche actuelle.

b_j : Biais associé au neurone j .

η : est le taux d'apprentissage.

$\partial J / \partial w_{ij}$: Dérivée partielle de la fonction de coût par rapport au poids w_{ij} , indiquant l'impact de ce poids sur l'erreur globale.

$\partial J / \partial b_j$: Dérivée partielle de la fonction de coût par rapport au biais b_j , montrant l'impact du biais sur l'erreur globale.

Ce processus itératif continue jusqu'à ce que le réseau atteigne un niveau de précision acceptable. Une fois ces algorithmes d'apprentissage suffisamment affinés, ils constituent un outil pour l'informatique et l'intelligence artificielle, permettant de classer et de regrouper très rapidement les données. De même, dans le traitement du langage naturel, les réseaux de neurones peuvent apprendre à comprendre et à générer du texte, permettant des applications comme la traduction automatique et la synthèse de texte [27].

Les applications des réseaux de neurones ne se limitent pas à aux traitements d'images et aux langages. Ils sont également utilisés dans des domaines tels que la prédiction financière, où ils peuvent analyser des tendances complexes dans les données de marché pour prévoir les mouvements des prix [27]. Dans le domaine médical, les réseaux de neurones sont utilisés pour diagnostiquer des maladies à partir de données d'imagerie médicale, comme les radiographies ou les IRM, souvent avec une précision comparable, voire supérieure, à celle des experts humains[28].

Le succès des réseaux de neurones dans ces diverses applications repose en grande partie sur leur capacité à apprendre des représentations profondes et hiérarchiques des données. Contrairement aux modèles d'apprentissage automatique traditionnels qui nécessitent souvent une

extraction manuelle des caractéristiques, les réseaux de neurones peuvent automatiquement apprendre les caractéristiques les plus pertinentes à partir des données brutes. Cette capacité à découvrir des motifs cachés dans les données rend les réseaux de neurones particulièrement adaptés aux tâches où les relations entre les variables d'entrée sont complexes et non linéaires [29].

En conclusion, les réseaux de neurones artificiels représentent une avancée majeure dans le domaine de l'apprentissage automatique et de l'intelligence artificielle. Leur capacité à apprendre à partir de grandes quantités de données et à modéliser des relations complexes les rend indispensables dans de nombreuses applications modernes. Grâce à leur structure inspirée du cerveau humain et à des algorithmes d'apprentissage comme la rétropropagation, les réseaux de neurones continuent de repousser les limites de l'intelligence artificielle.




Figure 1.6 Architecture d'un réseau de neurone multicouche [25]

1.8.1 Perceptron multicouche (MLP)

L'architecture du perceptron multicouche [30] (PMC ou MLP en anglais), est un type de réseau neuronal artificiel organisé en plusieurs couches (Voir figure 1.6). Un perceptron multicouche possède au moins trois couches qui sont : une couche d'entrée, au moins une couche cachée, et une couche de sortie.

Chaque couche est constituée d'un nombre (potentiellement différent) de neurones.

L'information circule de la couche d'entrée vers la couche de sortie uniquement : il

s'agit donc d'un réseau à propagation directe.

Le perceptron a été inventé en 1957 par Frank Rosenblatt. Dans sa première version, le perceptron était alors monocouche et n'avait qu'une seule sortie à laquelle toutes les entrées étaient connectées. Les premiers perceptrons n'étaient pas capables de résoudre des problèmes non linéaires comme le OU exclusif (XOR). Cette limitation fut supprimée au travers de la rétropropagation du gradient de l'erreur dans les systèmes multicouches[30].

Dans le perceptron multicouche à rétropropagation, les neurones d'une couche sont reliés à la totalité des neurones des couches adjacentes. Ces liaisons sont soumises à un coefficient altérant l'effet de l'information sur le neurone de destination. Ainsi, le poids de chacune de ces liaisons est l'élément clef du fonctionnement du réseau. La mise en place d'un perceptron multicouche pour résoudre un problème passe donc par la détermination des meilleurs poids applicables à chacune des connexions inter-neurales.




Figure 1.7: Architecture d'un réseau de neurones artificiels MLP [31].

1.8.2 Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs [32] (CNN) sont une classe de réseaux de neurones profonds spécifiquement conçus pour traiter les données structurées comme les images. Ils se composent de plusieurs types de couches, chacune jouant un rôle spécifique dans le traitement et l'extraction des caractéristiques des données d'entrée. A savoir la couche de convolution, la couche d'activation, la couche de pooling, la couche entièrement connectée et la couche de normalisation. La couche de convolution applique des filtres (ou noyaux) à l'image d'entrée pour extraire des caractéristiques locales. Chaque filtre génère une carte de caractéristiques (feature map) qui met en évidence des motifs spécifiques dans l'image, comme les bords ou les textures (Voir figure 1.7).

La convolution est définie par :

$$(f * g)(x, y) = \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} f(i, j) \cdot g(x - i, y - j)$$

Où f est le filtre et g est l'image

La fonction d'activation rectifiée linéaire (ReLU) est appliquée aux cartes de caractéristiques pour introduire de la non-linéarité. La fonction ReLU est définie par : $ReLU(x) = \max(0, x)$

La couche de pooling réduit la dimensionnalité des cartes de caractéristiques en résumant les informations dans des sous-régions de la carte de caractéristiques. Le pooling max, par exemple, prend la valeur maximale dans chaque sous-région. Cela aide à rendre le modèle invariant aux translations et à réduire le surajustement [32].




Figure 1.8 : Architecture d'un réseau de neurone CNN [33]

Les cartes de caractéristiques réduites sont aplaties en un vecteur et passées à travers des couches entièrement connectées (dense layers), où chaque neurone est connecté à tous les neurones de la couche précédente. Ces couches combinent les caractéristiques extraites pour effectuer la classification. Dans une problématique de classification, la couche de sortie utilise une fonction d'activation, comme Softmax, pour produire des probabilités de classe pour chaque catégorie d'objets. La classe avec la probabilité la plus élevée est choisie comme prédiction finale.

1.8.3 Modèle de Kohonen (SOM)

Le modèle de Kohonen [34], également connu sous le nom de carte auto-adaptative ou carte auto-organisatrice (Self Organizing Map, SOM), est un type de réseau de neurones artificiels basé sur des méthodes d'apprentissage non supervisées. Il a été développé par le statisticien Teuvo Kohonen en 1982 [34].

Dans ce modèle, les neurones sont organisés dans une grille, généralement unidimensionnelle ou bidimensionnelle. Chaque neurone est associé à un vecteur référent, qui est responsable d'une zone dans l'espace des données. Les vecteurs référents fournissent une représentation discrète de l'espace d'entrée et sont positionnés de manière à conserver la forme topologique de l'espace d'entrée (Voir figure 1.8).

Le modèle de Kohonen est souvent utilisé pour cartographier un espace réel, c'est-à-dire pour étudier la répartition de données dans un espace à grande dimension. En pratique, cette cartographie peut servir à réaliser des tâches de discrétisation, de quantification vectorielle ou de classification. La méthode proposée par Kohonen consiste à projeter l'espace des données observées (de grande dimension) sur un espace de faible dimension ; en général 1, 2 ou 3D, appelé carte. Cette dernière est formée d'un ensemble de neurones connectés entre eux selon la notion de voisinage. Chaque neurone possède des coordonnées fixes sur l'espace de la carte et des coordonnées adaptables sur l'espace des données appelées aussi vecteurs référents, responsables d'une zone de cet espace.




Figure 1.9: Architecture des cartes auto-organisatrices (SOM) [35].

Conclusion

Ce chapitre, a exploré les fondements théoriques et les concepts essentiels des techniques biométriques, avec un accent particulier mis sur la reconnaissance de l'iris. Nous avons défini les principales méthodes biométriques, telles que la reconnaissance des empreintes digitales, la reconnaissance faciale, la reconnaissance de l'iris, la reconnaissance vocale et la reconnaissance de la signature. Chaque technique présente des avantages uniques et des applications spécifiques, allant de la sécurité et du contrôle d'accès à l'authentification des transactions financières et à la protection des documents sensibles.

Nous avons également détaillé les étapes clés d'un système de reconnaissance de l'iris, depuis l'acquisition de l'image, en passant par le prétraitement, la segmentation, la normalisation et l'extraction des caractéristiques. Les concepts de base des Local Binary Patterns (LBP) et des réseaux de neurones autoorganisés (SOM) ont été introduits, soulignant leur rôle dans le traitement et l'analyse des images biométriques. Les LBP, avec leur efficacité dans l'extraction de motifs texturaux locaux et les SOM, avec leur capacité à cartographier des données multidimensionnelles en deux dimensions, illustrent les avancées technologiques dans le domaine de la biométrie.

La compréhension de ces concepts et définitions établit une base solide pour les chapitres suivants, dans lesquels nous explorerons les méthodes spécifiques et les applications pratiques de ces techniques biométriques. Cette connaissance est essentielle pour développer et améliorer les systèmes de reconnaissance biométrique, en assurant une identification et une authentification précises et sécurisées dans diverses applications. Dans le chapitre suivant, nous explorerons les études antérieures menées par d'autres auteurs sur la reconnaissance de l'iris.

CHAPITRE 2 : REVUE DE LITTÉRATURE

Introduction

Cette revue de littérature vise à fournir une analyse approfondie des études précédentes, les méthodes utilisées, les bases de données, les classificateurs appliqués, et les résultats et performances obtenus par différents chercheurs du domaine. Nous présenterons un tableau récapitulatif qui synthétise les principales études similaires réalisées dans le domaine. Le tableau permettra de comparer les approches, les résultats obtenus, ainsi que les méthodologies employées, afin de dresser un portrait d'ensemble des contributions majeures et des tendances actuelles dans la recherche sur ce sujet.

2.1 Méthodes traditionnelles de reconnaissance de l'iris

Les méthodes traditionnelles de reconnaissance de l'iris se basent sur des techniques de traitement d'image et d'extraction de caractéristiques développées avant l'ère des méthodes d'apprentissage profond.

En 2010, Santos et Hoyle [36] ont proposé une méthode innovante pour la reconnaissance de l'iris basée sur des graphes. Leur approche exploite la structure spatiale de l'iris en modélisant les relations entre les caractéristiques sous forme de graphes. Cette méthode a montré des résultats prometteurs en termes de précision et de robustesse.

Les graphes sont des structures mathématiques utilisées pour modéliser les relations entre des objets. Dans le contexte de la reconnaissance de l'iris, les nœuds du graphe représentent des points caractéristiques de l'iris, et les arêtes représentent les relations spatiales entre ces points. Cette modélisation permet de capturer la structure géométrique de l'iris de manière efficace. Après le prétraitement l'iris est extrait de l'image de l'œil et normalisé pour compenser les variations dues à la taille de la pupille et à l'orientation de l'œil. Cette normalisation permet de représenter l'iris de manière standardisée. Les points caractéristiques de l'iris sont alors extraits en utilisant des techniques de détection de points d'intérêt, telles que les détecteurs de coins ou les détecteurs de

$$R = \det(M) - k \cdot (\text{trace}(M))^2$$

Où M est la matrice des gradients d'intensité calculée à partir des dérivées de l'image, définie comme :

$$M = \begin{pmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{pmatrix}$$

I_x et I_y Sont les dérivées de l'image dans les directions x et y , respectivement.

$\text{Det}(M) = I_x^2 \cdot I_y^2 - (I_x I_y)^2$ est le déterminant de la matrice M .

$\text{Trace}(M) = I_x^2 + I_y^2$ est la trace de la matrice M .

k est une constante empirique généralement choisie dans l'intervalle $[0.04 - 0.06]$.

Ces points représentent des caractéristiques distinctives de l'iris. Un graphe est construit en utilisant les points caractéristiques comme nœuds et en établissant des arêtes entre les nœuds en fonction de la distance euclidienne et de la direction entre les points. Les arêtes peuvent également inclure des poids représentant la force des relations spatiales.

Une comparaison entre deux iris est alors effectuée en comparant leurs graphes respectifs. Des mesures de similarité graphique, telles que la distance graphique ou les algorithmes d'isomorphisme de sous-graphe, sont utilisées pour évaluer la similarité entre les graphes. La distance graphique peut être calculée en utilisant la méthode de distance de l'édition de graphe, qui mesure le coût minimal des transformations nécessaires pour transformer un graphe en un autre.

Les graphes de l'iris sont classifiés en utilisant des classificateurs basés sur des distances graphiques. Les distances entre les graphes de test et les graphes de référence sont calculés, et l'iris est classifié en fonction de la distance minimale ou d'autres critères de similarité.

Leur méthode a été testée sur la base de données UBIRIS.v1[36], obtenant une précision de 96,8 %, un taux de fausses acceptations (FAR) de 0,2 % et un taux de faux rejets (FRR) de 0,25 %.

Leur méthode [36] a montré que les graphes peuvent capturer de manière efficace les structures géométriques de l'iris.

John Daugman [37] a introduit une méthode de reconnaissance de l'iris basée sur l'utilisation de transformées de Gabor pour extraire des caractéristiques discriminantes. Cette technique repose sur la représentation mathématique des motifs complexes présents dans l'iris, qui sont uniques à chaque individu. Les transformées de Gabor sont particulièrement efficaces pour cette tâche en raison de leur capacité à analyser les informations fréquentielles et spatiales simultanément. Elles permettent de décomposer une image en ses composants fréquentiels. Elles sont définies par la fonction suivante :

$$G(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \psi\right)$$

Où :

$$x' = x \cos \theta + y \sin \theta$$

$$y' = x \sin \theta + y \cos \theta$$

σ (écart-type) : Contrôle la largeur de la gaussienne, définissant ainsi la taille du filtre. Plus σ est grand, plus la réponse du filtre couvre une grande région de l'image.

γ (facteur d'aspect) : Définit l'excentricité de la gaussienne. Si $\gamma=1$, la gaussienne est isotrope (circulaire). Si $\gamma<1$, elle est étirée dans une direction.

λ (longueur d'onde) : Détermine la fréquence spatiale de l'onde sinusoïdale. Plus λ est petit, plus les oscillations sont fréquentes.

ψ (phase) : Définit le décalage de phase de l'onde sinusoïdale. Une phase de 0 correspond à un cosinus centré sur 1, tandis qu'une phase de $\pi/2$ correspond à un sinus.

En appliquant cette fonction à l'image de l'iris, Daugman a pu extraire un ensemble de caractéristiques qui décrivent les variations locales de l'intensité lumineuse.

Les caractéristiques extraites par les transformées de Gabor sont utilisées pour générer un code binaire appelé <<code d'iris>>. Chaque bit de ce code représente une caractéristique spécifique de l'iris. La comparaison entre deux codes d'iris est effectuée en calculant la distance de Hamming1, qui mesure la différence binaire entre les deux codes :

$$H(A,B) = \frac{1}{N} \sum_{i=1}^N (A_i \oplus B_i)$$

Où A et B sont les codes d'iris à comparer, N est la longueur des codes et \oplus représente l'opération XOR.

L'algorithme a été sur la base de données CASIA-IrisV1 [37], qui contient des images d'iris capturées dans des conditions contrôlées et a obtenu une précision de 99,9%, un taux de fausses acceptations de 0,08% et un taux de faux rejets de 0,07%.

Ces résultats démontrent la haute précision et la fiabilité de la méthode de Daugman. La faible valeur de FAR indique que le système commet très peu d'erreurs en acceptant incorrectement une iris non correspondante, tandis que la faible valeur de FRR montre que le système rejette rarement une iris correcte. Le travail de Daugman a eu un impact significatif sur le domaine de la biométrie. Son approche basée sur les transformées de Gabor et le codage binaire de l'iris a posé les bases de nombreux systèmes de reconnaissance de l'iris modernes. La robustesse et la précision de sa méthode ont fait de la reconnaissance de l'iris une technologie fiable pour des applications de sécurité et d'identification personnelle.

Robert P. Wildes [17] a aussi contribué significativement aux techniques de reconnaissance de l'iris, en introduisant des méthodes basées sur la corrélation pour améliorer la robustesse de la reconnaissance. Ses travaux ont permis d'accroître la précision des systèmes de reconnaissance de l'iris, particulièrement dans des conditions variées.

Cette méthode repose sur l'utilisation de descripteurs de corrélation pour capturer les caractéristiques distinctives de l'iris et sur des techniques de corrélation statistique pour comparer les modèles d'iris. Les descripteurs de corrélation utilisés par Wildes sont dérivés de l'analyse des motifs texturaux de l'iris.

L'idée est de représenter l'iris par un ensemble de caractéristiques qui capturent les variations spatiales de l'intensité des pixels. Ces descripteurs sont ensuite utilisés pour effectuer des comparaisons entre différentes images d'iris. L'iris est d'abord segmenté de l'image de l'œil et normalisé pour compenser les variations dues à la taille de la pupille et à l'orientation de l'œil. Cette normalisation permet de représenter l'iris de manière uniforme, facilitant les comparaisons ultérieures. Les caractéristiques texturales de l'iris sont extraites en utilisant des filtres qui capturent les variations spatiales de l'intensité. Les descripteurs de corrélation sont ensuite dérivés de ces caractéristiques. Pour comparer deux iris, Wildes utilise la corrélation statistique entre leurs descripteurs de caractéristiques.

La corrélation est calculée en utilisant la formule:

$$C(A, B) = \frac{\sum (A_i - \mu_A)(B_i - \mu_B)}{\sqrt{\sum (A_i - \mu_A)^2 \sum (B_i - \mu_B)^2}}$$

Où A et B sont les vecteurs de descripteurs de deux iris, et μ_A et μ_B sont leurs moyennes respectives.

La décision de correspondance est prise en fonction du coefficient de corrélation. Un seuil est défini pour déterminer si deux iris correspondent ou non. Si le coefficient de corrélation dépasse ce seuil, les iris sont considérés comme appartenant au même individu.

Les résultats obtenus étaient d'une précision de 98,6%, un taux de fausses acceptations (FAR) de 0,1% et taux de faux rejets (FRR). Ces résultats montrent une haute précision de la méthode de Wildes, avec un faible taux de fausses acceptations et de faux rejets. Cela montre la robustesse de la méthode basée sur la corrélation pour la reconnaissance de l'iris, même dans des conditions variées.

Les travaux de Wildes ont eu un impact important sur le domaine de la biométrie. En introduisant des méthodes de corrélation pour la reconnaissance de l'iris, il a fourni une approche alternative

aux techniques basées sur les transformées de Gabor. Sa méthode est particulièrement utile dans des conditions où les images de l'iris peuvent être dégradées ou partiellement obstruées.

Boles et Boashash [38] ont proposé une méthode novatrice en 1998, utilisant les transformées de phase pour l'extraction des caractéristiques de l'iris. Leur approche a apporté des améliorations significatives dans la précision de la reconnaissance de l'iris, en particulier dans des conditions variées. Les transformées de phase sont utilisées pour capturer les informations de phase des signaux, qui sont cruciales pour identifier les motifs et les caractéristiques distinctives dans les images de l'iris. Contrairement aux méthodes qui se concentrent sur l'amplitude des signaux, les transformées de phase mettent en avant les informations de phase, offrant ainsi une meilleure caractérisation des motifs périodiques et des textures fines de l'iris, suivie par l'application de classificateurs utilisant la distance euclidienne pour la reconnaissance. Comme dans de nombreuses méthodes de reconnaissance de l'iris, le prétraitement de l'image est une étape cruciale. Cela inclut la réduction du bruit, l'amélioration du contraste et la normalisation de l'image pour assurer une représentation uniforme de l'iris. L'iris est segmentée de l'image de l'œil, et la région de l'iris est normalisée pour compenser les variations de taille et d'orientation. Cela permet de représenter l'iris de manière standardisée. L'extraction des caractéristiques de phase est réalisée en utilisant les transformées de phase. Cette méthode se concentre sur les variations de phase des motifs de l'iris, permettant une capture précise des structures périodiques et des textures fines. La transformée de phase est définie par :

$$TP = \arg (TF(I(x, y)))$$

Où *arg* représente l'argument complexe, et *TF* (*I* (*x*, *y*)) est la transformée de Fourier de l'image de l'iris.

Les caractéristiques extraites sont ensuite comparées à une base de données de caractéristiques connues en utilisant la distance euclidienne.

Leur méthode a été testée sur la base de données Bath Iris Image Database [38], obtenant une précision de 95%, un taux de fausses acceptations : 0,2% et un taux de faux rejets : 0,3%. Ces résultats montrent que la méthode basée sur les transformées de phase est efficace pour la reconnaissance de l'iris. Le taux de précision, les faibles taux de FAR et de FRR démontrent la robustesse de cette méthode, même dans des conditions variées.

Boles et Boashash [38] ont introduit une nouvelle approche pour la reconnaissance de l'iris, mettant l'accent sur les informations de phase plutôt que sur l'amplitude. Cette approche a prouvé son efficacité en capturant des caractéristiques distinctives de l'iris, ce qui a conduit à une amélioration significative de la précision et de la robustesse des systèmes de reconnaissance de l'iris. Leur méthode a également montré que l'utilisation de la distance euclidienne pour la classification pouvait être très efficace lorsqu'elle est combinée avec des caractéristiques de phase. Contrairement aux méthodes traditionnelles qui se concentrent principalement sur l'extraction de caractéristiques globales ou la modélisation des relations spatiales à travers des graphes ou des transformées de Gabor, notre approche combine l'extraction de caractéristiques locales par le biais des Local Binary Patterns (LBP) et une cartographie de ces caractéristiques à l'aide des Self-Organizing Maps (SOM). Cette combinaison permet de capturer à la fois des détails fins et des structures plus globales de l'iris. Notre approche se distingue par sa capacité à équilibrer la robustesse aux variations locales et la fidélité aux motifs globaux, offrant une alternative plus flexible que les méthodes traditionnelles de reconnaissance de l'iris.

2.2 Méthodes basées sur les réseaux de neurones

Ma et al. [39] ont exploré l'application des réseaux de neurones artificiels pour la reconnaissance de l'iris, apportant une nouvelle dimension à ce domaine grâce à l'utilisation de techniques d'apprentissage automatique. Leur approche a montré des résultats prometteurs, mettant en évidence le potentiel des réseaux de neurones à capturer et à discriminer les caractéristiques complexes de l'iris.

La normalisation permet de représenter l'iris de manière uniforme, facilitant les comparaisons ultérieures. Les caractéristiques de l'iris sont extraites en utilisant des méthodes de traitement

d'image avancées. Ces caractéristiques sont ensuite utilisées comme entrées pour le réseau de neurones.

Le réseau de neurones utilisé par Ma et Al est un perceptron multicouche, entraîné de manière supervisée, sur la base de données CASIA-IrisV1[39]. Cette base fournit un ensemble diversifié d'images d'iris. Une fois entraîné, le réseau de neurones est utilisé pour classifier les images d'iris. Les caractéristiques extraites des images d'iris de test sont passées à travers le réseau, et la sortie du réseau indique la classe prédite (c'est-à-dire, l'identité de l'individu).

Ma et Al [39] ont obtenu une précision de 97,5%%, un taux de fausses acceptations (FAR) de 0,12% et un taux de faux rejets (FRR) de 0,15%.

Les résultats montrent que l'utilisation des réseaux de neurones pour la reconnaissance de l'iris peut fournir une bonne précision avec des taux de fausses acceptations et de fausses rejets relativement faibles.

Leur méthode a montré que les réseaux de neurones peuvent capturer des caractéristique complexes et non linéaires de l'iris, surpassant certaines méthodes traditionnelles basées sur des descripteurs manuels. Cette approche a ouvert la voie à de nombreuses recherches ultérieures dans l'application de l'apprentissage automatique à la biométrie et à la reconnaissance de l'iris.

En 2017, Zhao et Kumar [40] ont exploré l'application des réseaux de neurones convolutifs (CNN) à la reconnaissance de l'iris, apportant une avancée significative grâce à l'utilisation de techniques d'apprentissages profonds. Leur méthode a permis d'obtenir une excellente précision en exploitant les capacités des CNN à extraire des caractéristiques multi-échelle de l'iris. En général, les réseaux de convolution sont particulièrement efficaces pour les tâches de reconnaissance d'image en raison de leur capacité à apprendre des caractéristiques invariantes aux transformations géométriques et aux variations d'éclairage.

L'architecture du CNN utilisée par Zhao et Kumar dans [40] comporte six couches de convolution, suivies de trois couches de pooling et d'une couche de sortie. Le CNN a ensuite été entraîné sur des images d'iris annotées de la base de données CASIA-IrisV4[40]. L'algorithme de

rétropropagation et l'optimisation par descente de gradient stochastique (SGD) est utilisé pour ajuster les poids du réseau, minimisant la fonction de coût de l'erreur entre les prédictions du réseau et les étiquettes réelles. Une fois entraîné, le CNN est utilisé pour classifier et indiquer l'identité de l'individu. Les auteurs ont obtenu une précision de 99,2%, un taux de fausses acceptations (FAR) de 0,05% et un taux de fausses rejets (FRR) de 0,07%. Les résultats montrent que l'utilisation des CNN pour la reconnaissance de l'iris peut fournir une très bonne précision avec des taux de fausses acceptations et de faux rejets extrêmement faibles. La capacité des CNN à extraire des caractéristiques multi-échelle a permis d'améliorer la robustesse et la fiabilité de la reconnaissance.

Cette approche a ouvert de nouvelles perspectives pour l'application de l'apprentissage profond à la biométrie et à la reconnaissance de l'iris. Cependant, les variations entre les différents capteurs d'iris peuvent poser des défis significatifs pour les systèmes de reconnaissance. Gangwar et Joshi [31] ont proposé une nouvelle architecture de réseau de neurones profonds, pour traiter ces variations et améliorer la précision de la reconnaissance de l'iris, en particulier dans les scénarios de reconnaissance croisée entre différents capteurs. Ils avaient pour objectif d'évaluer la performance du modèle dans des scénarios où les images d'entraînement et de test proviennent de capteurs différents. Leur modèle a été entraîné sur des images d'un capteur spécifique et testé sur des images d'un autre capteur pour vérifier la robustesse et la généralisation du modèle.

DeepIrisNet a démontré une capacité supérieure à généraliser entre différents capteurs, avec une précision de reconnaissance croisée dépassant 97%.

Les résultats montrent que l'architecture proposée peut effectivement traiter les variations inter-capteurs, réduisant les erreurs de reconnaissance dues aux différences de capture.

Gangwar et Joshi[41] ont démontré que DeepIrisNet offre une solution efficace et robuste pour la reconnaissance de l'iris, y compris dans des scénarios de reconnaissance croisée entre capteurs.

Minaee, Abdolrashidi, et Wang [41] ont proposé une nouvelle approche combinant la transformation de diffusion et les réseaux de neurones profonds pour améliorer la reconnaissance de l'iris.

L'approche proposée par les auteurs utilise la transformation de diffusion pour extraire des caractéristiques robustes des images d'iris. La transformation de diffusion est une technique d'analyse multi-échelle [41] qui décompose l'image en différentes échelles de fréquence, pour capturer les motifs texturaux à différentes résolutions. Les coefficients de diffusion obtenus sont ensuite utilisés comme caractéristiques d'entrée pour un réseau de neurones convolutifs (CNN). Les auteurs ont utilisé la base de données CASIA-IrisV4 pour évaluer leur approche[41].

L'approche proposée a montré des résultats prometteurs en termes de précision et de robustesse. Le modèle a atteint une précision de 99,3% sur la base de données CASIA-IrisV4, démontrant sa capacité à discriminer efficacement les iris. Le taux de fausses acceptations (FAR) a été rapporté à 0,04% et le taux de faux rejets (FRR) à 0,06%, ce qui est une bonne précision avec des taux d'erreurs très faibles. Les auteurs [41] ont également testé leur modèle dans des scénarios de reconnaissance croisée entre capteurs, où les images d'entraînement et de test proviennent de capteurs différents. Les résultats montrent que le modèle conserve une précision élevée, illustrant sa robustesse face aux variations inter-capteurs. La combinaison de la transformation de diffusion et des réseaux de neurones profonds permet de capturer des caractéristiques multi-échelles de l'iris, améliorant la performance du modèle dans des conditions réelles et variées.

Les résultats obtenus démontrent que la combinaison de la transformation de diffusion et des CNN peut fournir des performances supérieures pour la reconnaissance de l'iris.

Bien que les CNN soient puissants pour capturer des motifs complexes et hiérarchiques dans les données, ils nécessitent généralement une grande quantité de données d'entraînement et sont souvent sensibles aux conditions d'acquisition des images.

2.3 Approches basées sur les LBP et hybride

Dans une étude récente, les auteurs [42] ont proposé une approche utilisant le cosinus de similarité pour déterminer le poids initial du réseau carte auto-organisatrice (SOM), dans le but d'améliorer la précision de la reconnaissance. Par ailleurs, ils ont souligné l'importance du processus de

localisation pour limiter la zone de l'image de l'iris à analyser, ce qui facilite le processus de reconnaissance. La méthode proposée dans cette étude combine la carte auto-organisatrice (SOM) et l'algorithme de Daugman. Cette méthode a été testée sur plusieurs individus en capturant l'iris de l'œil à l'aide d'une caméra numérique. Les images d'iris capturées ont été localisées en premier lieu à l'aide de l'algorithme de Daugman, avant que les caractéristiques des images ne soient extraites à l'aide des méthodes GLCM (Gray Level Co-occurrence Matrix) et **LBP** (Local Binary Patterns).

Lors des tests de comparaison de reconnaissance d'iris, la méthode proposée a atteint une précision de 85,50 %, contre 73,50 % sans le processus hybride appliqué au réseau SOM. Ces résultats mettent en évidence l'amélioration significative de la précision de reconnaissance d'iris obtenue grâce à l'approche hybride SOM et l'algorithme de Daugman.

Dans le cadre de l'évolution des descripteurs de texture pour la reconnaissance de l'iris, les Local Binary Patterns (LBP) se sont imposés comme l'une des techniques les plus importantes et les plus étudiées. L'article [42] explore l'utilisation de divers descripteurs basés sur les LBP pour la reconnaissance de l'iris. Cette étude se distingue par l'analyse de la performance du classificateur par quantification vectorielle d'apprentissage (LVQ) appliquée à ces descripteurs. En outre, elle évalue l'impact d'une mise en œuvre parallèle du système sur une plateforme multi-cœur, démontrant ainsi l'efficacité du classificateur LVQ dans ce contexte spécifique.

L'évaluation, réalisée sur la base de données CASIA-Iris-Interval, a montré que le LVQ, couplé aux descripteurs LBP, constitue une alternative efficace pour la reconnaissance de l'iris, avec un taux de reconnaissance de 98,36% et un gain de vitesse notable de 24,81x grâce à l'implémentation parallèle. Cette étude souligne le potentiel des LBP dans la reconnaissance de l'iris, tout en introduisant le LVQ comme un classificateur performant dans ce domaine.

En 2002, Ojala et al. [43] ont utilisé la méthode des motifs local binaire (LBP) pour la classification de textures. Cette technique a été initialement développée pour la reconnaissance faciale, mais a ensuite été adaptée à d'autres applications de reconnaissance biométrique, y compris la reconnaissance de l'iris. Les histogrammes LBP extraits des images d'iris sont utilisés comme caractéristiques d'entrée pour un classificateur basé sur des machines à vecteurs de support (SVM). Le SVM est un algorithme d'apprentissage supervisé qui trouve l'hyperplan optimal pour séparer

les données en différentes classes. En utilisant les descripteurs LBP, le SVM peut classifier efficacement les images d'iris. En effet, leur technique a été testée sur une base de données interne et obtiennent une précision de 96,5%, un taux de fausses acceptations de 0,15% et un taux de faux rejets de 0,2%.

Dans la même veine, Liao, S et al. [44], se focalisent sur l'amélioration des performances de la reconnaissance faciale en utilisant des Local Binary Patterns (LBP) multi-échelles. Les auteurs ont proposé une nouvelle méthode appelée Multi-Scale Block Local Binary Patterns (MBLBP) pour capturer les caractéristiques faciales à différentes échelles et améliorer la robustesse de la reconnaissance faciale.

Les MB-LBP sont conçus pour extraire les motifs texturaux locaux à plusieurs échelles, ce qui permet de capturer à la fois les détails fins et les structures globales du visage. Contrairement aux LBP classiques qui utilisent un voisinage fixe, les MB-LBP utilisent des blocs de différentes tailles pour générer des caractéristiques à plusieurs échelles. Pour chaque bloc, un LBP est calculé en comparant l'intensité moyenne des pixels à celle des blocs voisins, créant un code binaire pour chaque pixel. Les caractéristiques extraites des MB-LBP sont ensuite utilisées pour former un histogramme des motifs texturaux, qui sert de descripteur pour la reconnaissance faciale.

Les auteurs ont également proposé une méthode d'apprentissage supervisé pour optimiser les caractéristiques MB-LBP en fonction des données de formation. Cette approche permet de sélectionner les caractéristiques les plus discriminantes et de réduire la dimensionnalité des descripteurs, améliorant ainsi l'efficacité de la reconnaissance faciale.

Les résultats de l'étude montrent que les MB-LBP surpassent les LBP traditionnels et d'autres méthodes de reconnaissance faciale en termes de précision et de robustesse. Les tests ont été effectués sur plusieurs bases de données de reconnaissance faciale, y compris les bases de données FERET et CAS-PEAL-R1.

Sur la base de données FERET, les MB-LBP ont atteint une précision de reconnaissance faciale de 96,7%, ce qui représente une amélioration significative par rapport aux LBP

traditionnels. Les résultats montrent également que les MB-LBP sont robustes aux variations d'éclairage, de posture et d'expression faciale. La base de données FERET contient des images faciales prises dans des conditions variées, y compris des changements d'expression, de coiffure et d'accessoires, ce qui montre que les MB-LBP peuvent gérer efficacement ces variations.

Dans l'article [45], les auteurs ont fourni une analyse approfondie et complète des Local Binary Patterns (LBP) et de leurs applications dans le domaine de la vision par ordinateur. Cet ouvrage explore les diverses méthodes et applications des LBP, notamment dans la reconnaissance faciale, la classification de textures, et la reconnaissance de mouvements.

Les auteurs présentent les principes fondamentaux des Local Binary Patterns (LBP) et leur extension à diverses variantes telles que les LBP multi résolution et invariants à la rotation. Ils explorent également les approches d'intégration des LBP avec d'autres techniques de traitement d'image et d'apprentissage automatique pour améliorer les performances de reconnaissance. Les méthodologies présentées incluent des descriptions détaillées des algorithmes, des procédures de mise en œuvre, et des stratégies d'optimisation pour différentes applications de vision par ordinateur.

Les résultats présentés [45] démontrent la robustesse et l'efficacité des LBP dans diverses applications de vision par ordinateur. Les auteurs ont montré que les LBP offrent des performances de pointe dans la reconnaissance faciale, avec une précision élevée et une robustesse aux variations d'éclairage et de posture. Ils ont également souligné que les LBP sont efficaces pour la classification des textures, permettant de distinguer avec précision des motifs texturaux complexes dans des images variées. En outre, les LBP se sont avérés efficaces pour la reconnaissance des mouvements, capturant les changements temporels et spatiaux dans des séquences vidéo. Les auteurs ont comparé les LBP avec d'autres techniques de traitement d'image et d'apprentissage automatique, montrant que les LBP surpassent souvent ces méthodes en termes de précision, de robustesse, et de simplicité de calcul.

Ces résultats montrent que l'utilisation des LBP pour la reconnaissance de l'iris peut fournir une haute précision avec des taux de fausses acceptations et de faux rejets relativement faibles. L'intégration des LBP avec des classificateurs SVM a montré des performances élevées en termes de précision et de robustesse.

Toutefois, bien que les histogrammes de LBP soient puissants pour la classification via des techniques comme les machines à vecteurs de support (SVM), cette approche reste limitée dans sa capacité à organiser et à interpréter ces motifs locaux dans un contexte global.

Notre méthode, qui combine LBP avec les Self-Organizing Maps (SOM), dépasse cette limitation en ajoutant une étape supplémentaire d'organisation topologique des caractéristiques. Après l'extraction des motifs locaux par LBP, les SOM sont utilisés pour structurer ces motifs dans un espace de dimension réduite, tout en préservant les relations spatiales importantes. Cette approche permet non seulement de capturer les détails fins de l'iris, mais aussi de les organiser de manière à améliorer la différenciation entre les individus, même dans des conditions variées ou lorsque les motifs texturaux peuvent être similaires.

Le Tableau 2.1 ci-dessous présente un récapitulatif des études menées dans le domaine de la biométrie par d'autres auteurs. Il offre une vue d'ensemble des différentes approches, technologies, et résultats obtenus par divers chercheurs dans le domaine.

Réf.	Jeux de Données	Extraction des Caractéristiques	Classificateurs	Biométrie	Précision
[46]	MORPH-II, Adience Benchmark	CNN-ELM Hybride, filtre flou	ELM, SVM	Visage	88,2%
[47]	In-house, portail MBCGC, IIITD multispectral periocular	CNN, VGG-Face, extraire des caractéristiques profondes	SVM	Périoculaire	94%
[48]	FRGC, images web, FERET, images de groupes, sousensemble VISOB	CNN, VGG16-19, ResNet	SVM, MLP, KNN, Adaboost	Oculaire	87%
[49]	SDUMLA-HMT, capteurs FT-2BU	Fusion de MB-LBP, filtres BSIF	LDA, KNN, SVM	Visage, Iris, Empreintes digitales	95,34%
[50]	CAS-SIAT, CASIA-IrisInterval	Apprentissage profond, CNN	VGG16, VGG19	Iris	94%
[51]	GFI (L'ensemble de données original se compose de 3 000 images)	Apprentissage profond, ReLU, CNN, GD, rétropropagation	CNN	Iris	98%
[52]	CASIA-IrisDistance, MBGC faceoculaire	ULBP, BSA	SVM	Visageoculaire	89%

Tableau 2.1: Tableau récapitulatif d'autres études portant sur le domaine de la biométrie

Conclusion

Cette revue de littérature met en évidence les progrès significatifs réalisés dans le cadre de la biométrie en générale et particulièrement celui de la reconnaissance de l'iris. Des méthodes basées sur des traits spécifiques aux approches modernes intégrant l'apprentissage profond et les descripteurs de texture ont été passés en revue. Les résultats obtenus montrent une amélioration constante de la précision, grâce à l'utilisation de bases de données variées et des classificateurs. Ces avancées justifient une exploration approfondie dans notre étude pour développer une méthode encore plus performante.

CHAPITRE 3 : ARCHITECTURE PROPOSÉE

Introduction

Dans ce chapitre, nous détaillons l'architecture proposée ainsi que les méthodes employées pour développer notre système de reconnaissance de l'iris combinant les LBP et les SOM. Notre architecture est structurée en plusieurs étapes clés, chacune jouant un rôle crucial. Le choix de la méthode LBP pour l'extraction des caractéristiques s'explique par sa capacité à capturer efficacement les motifs texturaux locaux, un aspect essentiel dans la reconnaissance de l'iris. Par rapport à d'autres méthodes d'extraction comme les transformées de Gabor. La méthode LBP est moins coûteuse en termes de calculs et plus robuste face à des variations légères de l'image. D'un autre côté, SOM est particulièrement adapté à la classification non supervisée et excelle dans la tâche de reconnaissance en organisant les données de manière topologique, ce qui est crucial pour des systèmes de reconnaissance où des classes très proches peuvent être difficiles à discerner.

3.1 Prétraitement

Cette étape comprend plusieurs sous-processus visant à réduire le bruit, à améliorer le contraste et à standardiser les images. Le processus commence généralement par la réduction du bruit, qui vise à éliminer les artefacts indésirables causés par des variations de l'éclairage ou des imperfections du capteur. Des filtres de lissage comme le filtre médian ou les filtres gaussiens sont souvent utilisés pour cette tâche, car ils sont efficaces pour conserver les bords tout en réduisant le bruit [17].

Ensuite, l'amélioration du contraste est appliquée pour assurer que les détails de l'iris sont clairement visibles. Des techniques telles que l'égalisation d'histogramme sont couramment utilisées. L'égalisation d'histogramme redistribue les intensités de pixel de l'image pour utiliser pleinement la gamme de valeurs disponibles, ce qui accentue les différences entre les régions sombres et claires de l'image.

Une fois ces étapes accomplies, l'image est normalisée pour standardiser la taille et l'orientation de l'iris. Cela implique généralement la conversion de l'image d'iris en une représentation polaire,

où les coordonnées radiales et angulaires sont utilisées pour représenter les motifs de l'iris de manière uniforme. Cette transformation facilite la comparaison entre différentes images d'iris en alignant les structures principales de l'iris.

Ces étapes de prétraitement sont essentielles pour améliorer la qualité des images et garantir que les algorithmes de segmentation et d'extraction des caractéristiques puissent fonctionner de manière optimale. Les recherches ont montré que le prétraitement peut significativement améliorer la précision de la reconnaissance de l'iris en réduisant les erreurs causées par des facteurs externes [16].

Segmentation de l'Iris

La segmentation vise à isoler précisément la région de l'iris de l'image oculaire [17]. Cette étape est essentielle pour garantir que seules les informations pertinentes de l'iris soient utilisées pour la reconnaissance. Le module de segmentation de l'iris consiste à séparer la région de l'iris des autres composantes de l'image de l'œil (cils, sourcils, paupières, etc.). Le problème revient à déterminer les frontières pupille/iris et iris/sclera, qui seront ensuite approchées par des contours paramétrés pour faciliter l'étape de normalisation ultérieurement.

La transformée de Hough [52] permet de trouver des instances imparfaites d'objets appartenant à une certaine classe de formes par un procédé de vote. Ce procédé de vote se fait dans un espace de paramètres, à partir duquel les candidats objets sont obtenus comme des maxima locaux dans un espace accumulateur qui est explicitement construit par l'algorithme pour calculer la transformée de Hough. Le point maximum dans l'espace de Hough correspondra aux coordonnées de rayon et de centre du meilleur cercle défini par les points de bord.

La transformée de Hough était destinée à l'identification de lignes dans l'image, mais elle a été étendue par la suite à l'identification de positions de formes arbitraires, le plus souvent des cercles ou des ellipses. La Figure 3.1 montre deux étapes cruciales du processus de reconnaissance de l'iris : (a) la région de l'iris elle-même, et (b) la localisation précise de la pupille et de l'iris, comme décrit dans l'étude [54]. Ces visualisations sont essentielles pour comprendre la segmentation de l'iris dans les systèmes biométriques.




Figure 3.1: (a) région de l'iris, (b) localisation de la pupille et de l'iris [54].

L'opérateur intégrro-différentiel proposée par John Daugman en 1993 [7] permet de maximiser la variation du contour de l'iris en fonction du rayon et du centre du cercle. Il utilise une fonction de noyau gaussien pour lisser l'image et réduire le bruit. Il est considéré comme l'une des méthodes les plus efficaces et les plus rapides pour la localisation de l'iris, comparée à la transformée de Hough. L'opérateur intégrro-différentiel est défini comme suit :

$$\max_{r, x_0, y_0} |G_{\sigma}(r) * \frac{\partial}{\partial r} \int_{\theta=0}^{2\pi} I(x_0 + r \cos(\theta), y_0 + r \sin(\theta)) d\theta|$$

Où $I(x, y)$ est l'image de l'œil, r est le rayon, x_0 et y_0 sont les coordonnées du centre du cercle, et $d\theta$ est un élément de longueur sur le contour du cercle.

L'opérateur intégrro-différentiel calcule la somme des dérivées partielles le long du contour du cercle pour chaque valeur de r , x_0 et y_0 . Le maximum de cette somme correspond à la position optimale du cercle de l'iris. Il peut également être utilisé pour détecter les paupières en modifiant le chemin d'intégration, passant d'une forme circulaire à un arc de cercle.

La Figure 3.2 illustre le processus de segmentation de l'iris à l'aide de la méthode intégrro-différentielle, telle que présentée dans l'étude [55]. Cette technique permet d'isoler précisément l'iris des autres parties de l'œil, facilitant ainsi une analyse plus précise.




Figure 3.2: Segmentation de l'Iris par la méthode intégrro-differentielle. [55]

3.2 Extraction des caractéristiques (LBP)

Afin d'obtenir le rectangle de l'iris, l'information la plus distinctive présentée dans un modèle d'iris doit être codée de telle sorte que des comparaisons entre les calibres puissent être faites. Dans cette étape, nous utilisons la méthode des motifs locaux binaires (LBP) pour l'extraction et le codage d'informations présente sur la texture de l'iris.

Chaque pixel de cette image contient un code LBP qui représente le motif local autour de ce pixel. Les valeurs LBP vont de 0 à 255, car elles sont représentées par des codes binaires de 8 bits. Chaque valeur LBP correspond à un motif spécifique dans l'image.

L'approche LBP permet de capturer des informations locales importantes tout en réduisant la dimensionnalité de l'image. Cette méthode est particulièrement utile pour des tâches de reconnaissance de motifs et de textures dans les images. Après avoir obtenu l'image LBP, l'image d'iris est divisée en quatre régions. Ensuite, nous calculons l'histogramme de chaque région et concaténons ces histogrammes pour former un vecteur de caractéristiques de taille 1024 valeurs représentant l'image d'iris.




Figure 3.3: Exemple d'un code de l'iris extrait par l'opérateur LBP [43]

3.3 Classification

Dans le cadre de notre travail, le SOM est utilisé pour la classification et la visualisation des données. En entraînant le SOM sur nos données, le système est capable de découvrir des structures sous-jacentes, de regrouper des données similaires, et de faciliter la compréhension des relations entre les différentes caractéristiques de nos données.

3.3.1 Composition et principe

Dans ce travail, nous utiliserons une grille unidimensionnelle. Chaque neurone dans cette grille est associé à un vecteur référent du neurone, \mathbf{I} est reconnu par wI avec $I \in \{1, \dots, 100\}$, I est l'indice du neurone dans la grille. L'objectif de l'apprentissage dans une SOM [21,26] est de mettre à jour ces vecteurs référents de manière qu'ils approximent au mieux la distribution des vecteurs d'entrée. Cela est généralement accompli en utilisant un processus itératif où chaque vecteur d'entrée est présenté au réseau, et le neurone dont le vecteur référent est le plus proche du vecteur d'entrée (le neurone gagnant) est identifié. Les vecteurs référents du neurone gagnant et de ses voisins sont ensuite ajustés pour se rapprocher du vecteur d'entrée.

Cela permet à la SOM d'apprendre la structure des données d'entrée et de former une représentation de bas niveau de ces données. Cette représentation conserve les relations topologiques entre les vecteurs d'entrée, ce qui signifie que les vecteurs d'entrée similaires seront mappés à des neurones proches sur la grille.

3.3.2 Modèle d'apprentissage

Dans un premier temps, une phase d'initialisation est réalisée, au cours de laquelle les connexions de poids entre les neurones sont établies de manière aléatoire. L'ensemble de l'apprentissage est préparé, contenant les vecteurs d'entrée, tels que les caractéristiques d'un jeu de

données. Ensuite, pour chaque vecteur d'entrée, le réseau recherche le neurone gagnant (ou winner). Le neurone gagnant est celui dont le vecteur associé est le plus similaire au vecteur d'entrée. La distance entre chaque neurone de la carte et le vecteur d'entrée est calculée (par exemple, en utilisant la distance euclidienne).

Le neurone gagnant est celui qui minimise cette distance :

$$\text{Neurone gagnant} = \operatorname{argmin}_i \{d_i\}$$

Avec :

d_i la distance entre le vecteur d'entrée et le vecteur de poids du neurone i

argmin_i donne l'indice du neurone i pour lequel la distance d_i est minimale.

Les poids des connexions du neurone gagnant sont modifiés pour que les vecteurs de poids se rapprochent davantage du vecteur d'entrée présenté à la grille. La règle de modification dépend du type de réseau et de l'algorithme d'apprentissage utilisé. Ce processus est répété jusqu'à ce qu'une convergence soit atteinte.

Enfin, pour toute nouvelle entrée (par exemple, un nouveau vecteur e), le réseau calcule le neurone vainqueur, qui est le plus proche de l'entrée.

Le neurone vainqueur représente l'identification de la personne ou de l'objet associé aux valeurs en entrée.

Les vecteurs de poids des neurones gagnant et voisins sont mis à jour selon une règle d'apprentissage, telle que :

$$w(t+1) = w(t) + \eta(t) \cdot h(t) \cdot (x(t) - w(t))$$

Où $w(t)$ est le vecteur de poids, $\eta(t)$ est le taux d'apprentissage, $h(t)$ est la fonction de voisinage, $x(t)$ est le vecteur d'entrée.

Conclusion

Dans ce chapitre, nous avons abordé les différentes étapes nécessaires au prétraitement de l'iris, comprenant la segmentation et la normalisation. Ces étapes sont fondamentales pour isoler et préparer l'iris en vue des étapes ultérieures d'analyse et de reconnaissance. Dans le chapitre suivant, nous implémenterons notre système en mettant en pratique les méthodes détaillées. Nous

mettrons en évidence l'efficacité de notre approche et discuterons des améliorations potentielles et des résultats.

CHAPITRE 4: IMPLEMENTATION ET RESUTATS

Introduction

Ce chapitre est consacré à la mise en œuvre de notre travail. Nous commencerons par présenter les outils de développement qui ont facilités la programmation, puis nous passerons en revue les principales étapes de la mise en œuvre. Ensuite, nous présenterons les résultats obtenus, avant de conclure par une discussion.

4.1 Outils & environnement

Le choix d'un environnement de programmation adéquat est crucial pour la progression de notre projet. Cette décision est influencée par divers éléments, tels que la capacité de montage, la simplicité d'usage, l'accessibilité des fonctionnalités, l'interaction avec d'autres environnements, et bien plus encore.

Notre système a été conçu sur une machine avec:

<i>Caractéristiques</i>	<i>Information</i>
<i>Processeur</i>	<i>AMD Ryzen 5 7535HS with Radeon Graphics 3.30 GHz</i>
<i>Mémoire vive installée</i>	<i>16,0 Go (15,2 Go utilisable)</i>
<i>Type du système</i>	<i>Système d'exploitation 64 bits, processeur x64</i>
<i>Édition</i>	<i>Windows 11 Professionnel</i>
<i>Version</i>	<i>23H2</i>
<i>Version du système d'exploitation</i>	<i>22631.3737</i>

Nous avons opté pour MATLAB (laboratoire Matriciel) qui est optimisé pour résoudre les problèmes scientifiques et techniques. Le langage MATLAB est basé sur les matrices[56]. C'est

un moyen naturel pour exprimer les mathématiques computationnelles. MATLAB est un logiciel accessible et productif conçu pour les ingénieurs et les scientifiques. Il est doté d'un éditeur permettant d'exécuter des séquences de commandes encapsulées dans des fonctions[56]. Grâce à sa vaste bibliothèque de boîtes à outils prédéfinies.

Le code MATLAB peut être intégré à d'autres langages, ce qui nous permet de déployer des algorithmes et des applications. À cela s'ajoute les graphiques intégrés permettant de visualiser facilement les données afin d'en dégager des informations. Il offre aussi des applications dédiées à l'ajustement de courbes, la classification de données, l'analyse de signaux et bien d'autres tâches spécialisées.

4.2 Base de données utilisée

Dans ce travail, nous avons opté pour la base de données CASIA-IrisV1 et CASIA-IrisV4. Les bases de données CASIA-Iris, développée par l'Institut d'Automatisation de l'Académie Chinoise des Sciences (CASIA) [16], est l'une des bases de données les plus utilisées pour la recherche en reconnaissance de l'iris (Voir figure 4.1). Elle a été créée pour fournir aux chercheurs un ensemble de données standardisé pour évaluer et comparer différentes méthodes de reconnaissance de l'iris.




Figure 4.1: Graphique illustrant le nombre de publications utilisant la base de données CASIA-Iris par année, de 2004 à 2023.

La base de données CASIA-IrisV1 contient des images de haute qualité de l'iris, capturées dans des conditions contrôlées. Elle comprend 756 images d'iris. Chaque image a une résolution de 320x280 pixels. Les images dans la base de données CASIA-IrisV1 sont au format BMP, ce qui préserve la qualité de l'image sans compression. La base de données CASIA-IrisV4 quant à elle est la version la plus complète avec plus de 54 601 images d'iris couvrant différents scénarios de capture. Les conditions d'éclairage et les angles de capture sont contrôlés de manière à minimiser les variations non dues à l'iris lui-même, ce qui rend cette base de données idéale pour tester des algorithmes de segmentation et de reconnaissance de l'iris. La base de données est également annotée avec des informations sur les sujets, y compris l'identité de l'œil (gauche ou droit) et le numéro de la session de capture, ce qui permet des tests rigoureux et reproductibles [16]. Les chercheurs peuvent utiliser cette base de données pour développer et valider de nouvelles techniques de reconnaissance de l'iris, en particulier celles qui nécessitent une grande précision et une robustesse face aux variations intersessions.




Figure 4.2: Image tirée de la base de données CASIA-IrisvV4 [16]

4.3 Prétraitement

Dans le cadre du prétraitement de nos données, la transformée de Hough a été appliquée sur certains échantillons de la base de données CASIA_IrisV1, et les résultats obtenus sont illustrés dans les figures 4.3 et 4.2.

La figure 4.3 a été convertie en niveaux de gris. La prochaine étape consiste à détecter les contours pour isoler les régions d'intérêt, telles que l'iris.

Image en niveaux de gris




Figure 4.3 : Image en niveaux de gris d'un iris de Casia-irisV1




Figure 4.4: Détection des contours

Nous avons converti l'image en niveaux de gris puis nous avons appliqué l'algorithme de Canny [57] pour détecter les contours (voir figure 4.4). Ensuite nous avons dessiné les contours sur une image noire pour visualiser, puis nous avons normalisé. La normalisation assure une cohérence telle que deux photographies du même iris, prises dans des conditions différentes, auront leurs caractéristiques alignées aux mêmes emplacements.

Ces contours mettent en évidence les bords de l'iris et d'autres éléments de l'image. Elle fournit une bonne base pour l'analyse des bords et des contours.



Figure 4.5: code de l'iris normalisé (base de données CASIA-IrisV1)

4.4 Extraction des caractéristiques (LBP)

La Figure 4.6 ci-dessous illustre les caractéristiques LBP (Local Binary Patterns) extraites à partir des images de notre base de données, représentées en fonction de l'index des caractéristiques. Chaque courbe correspond à la variation des valeurs pour différents indices, mettant en évidence la complexité et la variabilité des motifs texturaux capturés par la méthode LBP. La superposition des lignes indique que les variations de texture capturées par les LBP sont cohérentes entre les différents ensembles de données, mais avec des différences spécifiques. Les variations les plus élevées pourraient être particulièrement informatives pour notre tâche.

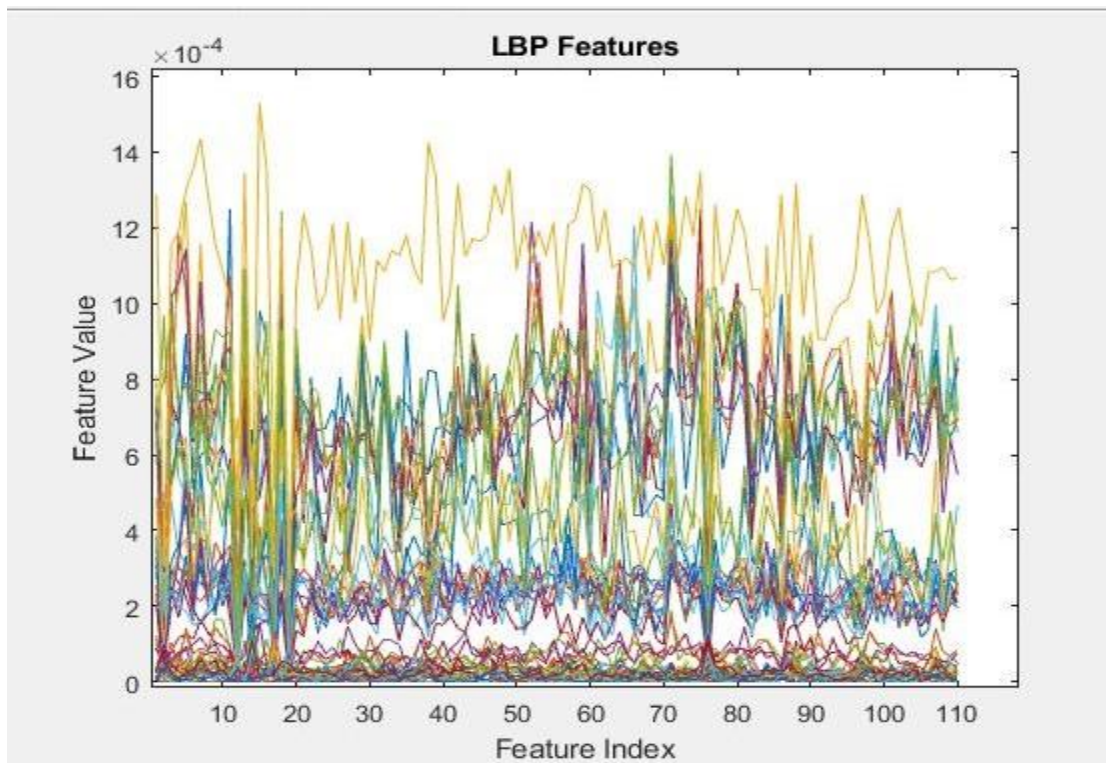


Figure 4.6 : Graphique de l'extraction des caractéristiques par la méthode LBP

4.5 Entraînement du modèle (SOM)

Les caractéristiques LBP extraites capturent des informations texturales importantes de l'image sous forme d'histogrammes, qui sont ensuite agrégés pour former un ensemble de vecteurs de caractéristiques (voir tableau 4.1 ci-dessous). Ces vecteurs sont ensuite utilisés pour entraîner le SOM, qui organise les données en fonction de leur similarité, facilitant la visualisation et la classification.

Images	Caractéristiques LBP 1	Caractéristiques LBP 2	Caractéristiques LBP 3
1	6.5025681e-04	2.3053438e-04	1.1057426e-05
2	9.1010028e-05	2.3260647e-05	5.8420800e-04
3	0.00067794154	0.00028740891	6.5577059e-04
4	0.00070235837	0.00030097543	7.5808458e-04

Tableau 4.1 : Extrait des caractéristiques de certaines images à l'aide de la méthode LBP

Unité	Valeur initiale	Valeur d'arrêt	Valeur cible
Époque	0	200	200
Temps écoulé	-	00:03:43	-

Tableau 4.2 : Tableau de progression de l'entraînement du modèle.

Cette section donne des détails sur l'évolution de l'entraînement

Époque : L'entraînement a commencé à l'époque 0, s'est arrêté à 200. Cela signifie que l'entraînement a été effectué bout de 200 époques.

Temps écoulé : Le temps total d'exécution de l'entraînement était de 00:03:43 (3 minutes et 43 secondes).

Data division	Batch weight/Bias rule
Performance	Mean Squared Error (MSE)
Logiciel	MATLAB

Tableau 4.3 : Tableau de l'algorithme d'entraînement

Data Division : La méthode utilisée pour diviser les données est la règle des poids/biais par batch (Batch Weight/Bias Rule). Cela suggère que l'ajustement des poids a été fait sur un ensemble d'échantillons en une seule fois (par lot).

Performance : La mesure de performance utilisée est l'erreur quadratique moyenne (MSE – Mean Squared Error), qui évalue l'erreur moyenne entre les résultats prévus par le réseau et les résultats réels.

SOM Topology	SOM Neighbor
SOM Neighbor Distance	SOM Input Plane
SOM Sample	SOM Weight Positions

Tableau 4.4 : Historique des graphiques d'entraînement.

Cette section liste les différents types de graphiques générés pour visualiser et analyser l'entraînement du SOM :

SOM Topology : Représente la topologie de la carte auto-organisatrice, montrant la structure du réseau.

SOM Neighbor Connections : Montre les connexions entre les neurones voisins.

SOM Neighbor Distances : Affiche les distances entre les neurones voisins, utile pour analyser la similarité entre les unités.

SOM Input Planes : Visualise comment les différents paramètres d'entrée influencent la carte.

SOM Sample Hits : Indique combien d'échantillons d'entraînement ont été attribués à chaque neurone du SOM.

SOM Weight Positions : Montre les positions des poids sur la carte, indiquant comment le réseau a organisé ses poids pendant l'entraînement.




Figure 4.7 : Topologie de la carte auto-organisatrice (SOM)

La figure 4.7 présente la topologie de notre carte auto-organisatrice (SOM) après plusieurs époques d'entraînement. La grille est constituée de cellules hexagonales, chacune représentant un neurone du SOM. Axe horizontal (X) représente l'indice des neurones de la carte SOM dans la direction horizontale. Les valeurs varient de **0 à 10**, ce qui signifie que la carte a environ **11 colonnes** de neurones. Axe vertical (Y) représente l'indice des neurones de la carte SOM dans la direction verticale. Les valeurs varient de **-1 à 8**, suggérant environ **10 lignes** de neurones (en comptant la marge). Chaque neurone a appris à représenter un cluster spécifique des données d'entrée. Le SOM a été entraîné pendant 200 époques, et chaque neurone correspond à un prototype des données d'entrée. Les distances entre ces prototypes permettent d'analyser la structure des données.

Les zones de la grille où les neurones sont plus rapprochés peuvent indiquer la présence de clusters de données similaires.

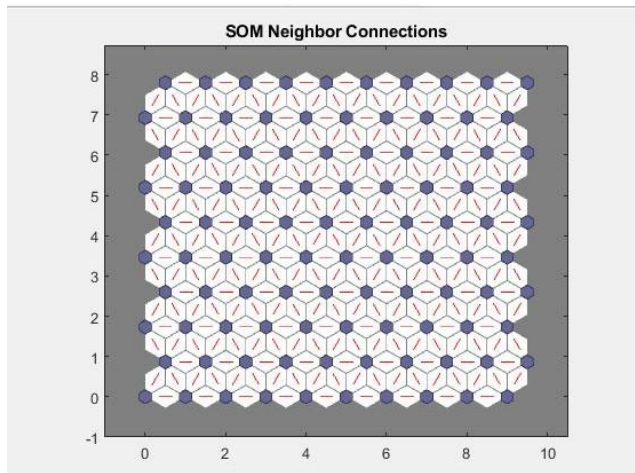


Figure 4.8 : Connexion de voisinage.

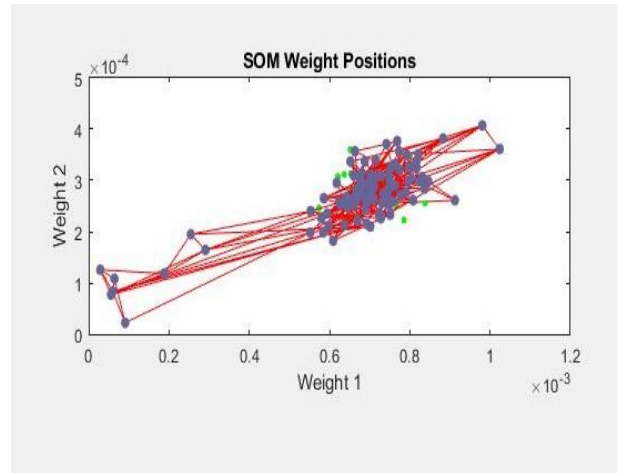


Figure 4.9 : positions des poids des neurones.

La figure 4.8 représente les connexions de voisinage dans notre carte auto-organisatrice (SOM). Les connexions entre les neurones montrent comment les neurones sont liés les uns aux autres, et les points bleus représentent les neurones individuels. La topologie hexagonale et les connexions de voisinage sont cruciales pour l'apprentissage et la représentation topologique des données dans la SOM.




Figure 4.10 : Distances de poids entre les neurones.

La figure 4.10 illustre les distances de poids, qui mesurent la similarité ou la dissimilarité entre les vecteurs de poids des neurones voisins dans une SOM. Les couleurs varient du jaune (indiquant des distances plus faibles) au rouge (distances intermédiaires) et au noir (distances plus grandes), reflétant les similarités et dissimilarités entre les neurones voisins. Les zones jaunes représentent des clusters homogènes, tandis que les régions noires marquent les frontières entre différents clusters.




Figure 4.11 : SOM Hits.

La figure : 4.11 montre la distribution dans notre carte auto-organisatrice (SOM). Les valeurs dans chaque cellule hexagonale indiquent la fréquence à laquelle chaque neurone a été sélectionné comme BMU (Best Matching Unit) pour les données d'entrée. Les neurones avec des valeurs élevées représentent des clusters de données denses et fréquents, tandis que ceux avec des valeurs de hits faibles indiquent des régions de variabilité ou des clusters moins fréquents. Cette visualisation est essentielle pour comprendre la structure et la distribution des données dans la SOM.

4.6 Résultats

Notre système de reconnaissance biométrique basé sur la combinaison des caractéristiques locales de l'iris (LBP) et l'apprentissage non supervisé par les cartes auto-organisatrices (SOM) a montré de très bonnes performances dans le domaine.

Indices	Valeurs
Nombre d'échantillons d'entraînement (base de données Casia-IrisV4)	10.000
Nombre d'échantillons (base de données Casia-IrisV1)	756
Taux de d'identification	99%
Temps de reconnaissance	0,01

Tableau 4.5 : Résumé des performances d'identification et des échantillons utilisés.

Le tableau (Tableau 4.5) résume les résultats obtenus lors des tests effectués sur un ensemble de données comprenant 756 échantillons. Voici une explication détaillée de ces résultats :

Nombre d'échantillons d'entraînement : Nous avons entraîné notre modèle sur ensemble de 10.000 images provenant de la base de données Casia-IrisV4.

Nombre d'échantillons : Le test a été réalisé sur un total de 756 échantillons, suffisamment grande pour tester la robustesse du modèle provenant de la base de données Casia-IrisV1.

Taux d'identification : Le modèle a atteint un taux d'identification de 99,00 %, ce qui donne la précision de la méthode utilisée.

Temps de reconnaissance: Le temps nécessaire pour effectuer une reconnaissance est de 0,01 seconde, montrant la rapidité du modèle. Cette vitesse est avantageuse pour les applications en temps réel.

Ces résultats montrent de la solidité et l'efficacité de notre approche, qui combine les avantages des LBP et des SOM pour une reconnaissance de l'iris. Ils ouvrent la voie à des applications

pratiques dans divers domaines nécessitant une identification biométrique sûre, efficace et rapide, tels que les contrôles d'accès sécurisés et les systèmes de gestion d'identité.

La figure 4.12 présente l'interface utilisateur de notre système, mettant en évidence l'agencement des éléments et les fonctionnalités disponibles. Cette interface a été conçue pour être intuitive, assurant une navigation fluide et facilitant l'accès aux différentes fonctionnalités de l'application.

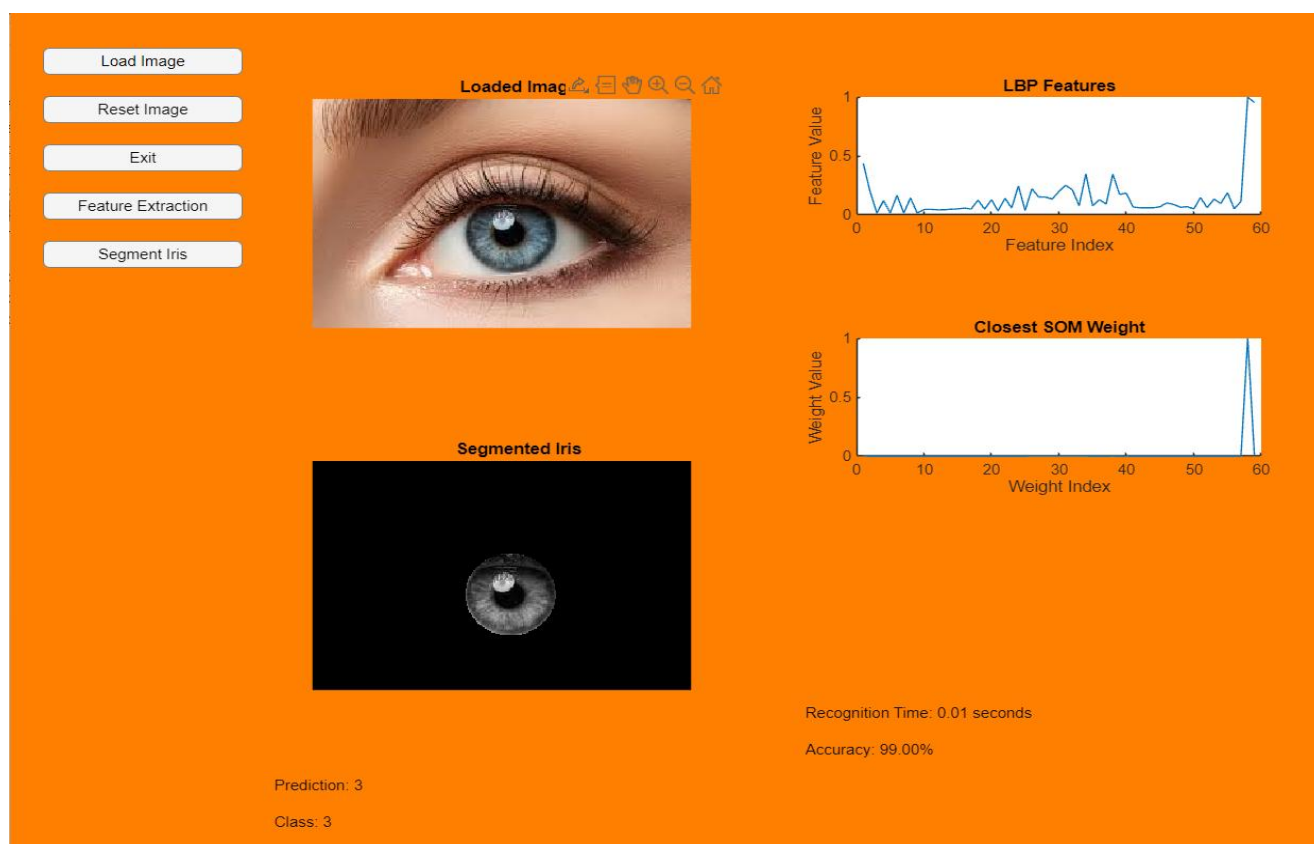


Figure 4.12 : Interface utilisateur de notre système

➤ Composants de l'interface utilisateur

Avant de détailler les composants de l'interface utilisateur de notre système, il est important de comprendre le rôle crucial que joue cette interface dans l'interaction avec

l'utilisateur. Conçue pour être à la fois intuitive et fonctionnelle, l'interface permet à l'utilisateur de charger une image, de segmenter l'iris, d'extraire des caractéristiques et d'analyser les résultats de manière efficace et rapide. Les différentes sections de l'interface sont organisées de manière à offrir une expérience utilisateur fluide, où chaque fonction est facilement accessible et compréhensible, même pour les utilisateurs moins expérimentés.

Maintenant, détaillons les différentes composantes de cette interface et leur rôle dans le processus global du système.

1. Boutons de Contrôle

- **Load Image** : Permet de charger une nouvelle image pour la classification.
- **Reset Image** : Réinitialise l'image chargée.
- **Exit** : Quitte l'application.
- **Feature Extraction** : Extraire les caractéristiques de l'image chargée.
- **Segment Iris** : Segmente l'iris de l'image chargée.

2. Images et Graphiques

- **Loaded Image** : Affiche l'image actuellement chargée. Dans ce cas, il s'agit d'une image en niveaux de gris d'un œil.
- **Segmented Iris** : Affiche l'image de l'iris segmenté.
- **LBP Features** : Affiche un graphique des caractéristiques LBP extraites de l'image chargée.
- **Closest SOM Weight** : Affiche un graphique des poids du neurone SOM le plus proche des caractéristiques LBP extraites.

3. Informations de Classification

- **Prediction** : Montre la classe prédite de l'image. Ici, la prédiction est 3.
- **Class** : Montre la classe réelle de l'image. Ici, la classe est 3.
- **Recognition Time** : Indique le temps de reconnaissance. Ici, il est de 0.01 secondes.
- **Accuracy** : Indique la précision de la classification. Ici, elle est de 99.00%.

Interprétation des Éléments

1. **Loaded Image**

- L'image affichée est une image en niveaux de gris d'un œil. Cette image est utilisée pour l'extraction des caractéristiques et la classification de l'iris.

2. **Segmented Iris**

- L'image affichée montre l'iris segmenté, ce qui signifie que la région de l'iris a été isolée de l'image de l'œil. Cette segmentation est essentielle pour extraire des caractéristiques précises de l'iris.

3. **LBP Features**

- Le graphique montre les caractéristiques LBP extraites de l'image chargée.
- L'axe des abscisses (X) représente les indices des caractéristiques LBP.
- L'axe des ordonnées (Y) représente les valeurs des caractéristiques LBP.
- Les variations dans les valeurs des caractéristiques LBP indique les différences de texture dans différentes parties de l'image de l'iris.

4. **Closest SOM Weight**

- Le graphique montre les poids du neurone SOM le plus proche des caractéristiques LBP extraites.
- L'axe des abscisses (X) représente les indices des poids des neurones dans la SOM.
- L'axe des ordonnées (Y) représente les valeurs des poids des neurones.
- Une forte correspondance entre les caractéristiques LBP et les poids du neurone SOM indique que le neurone représente bien les motifs de texture de l'image.

5. **Prediction et Class**

- La classe prédite est 3, et la classe réelle est également 3, indiquant que le modèle a correctement classifié l'image.

6. **Recognition Time et Accuracy**

- Le temps de reconnaissance est de 0.01 secondes, ce qui est rapide et efficace.
- La précision de la classification est de 99.00%, ce qui indique une très bonne performance du modèle.

Analyse Globale

1. Extraction des Caractéristiques LBP

- Les LBP sont utilisés pour extraire des caractéristiques de texture locale de l'image de l'iris. Ces caractéristiques sont utiles pour différencier les images basées sur les motifs de texture.

2. Utilisation de la SOM

- La SOM est utilisée pour organiser les caractéristiques de texture extraites en une carte où chaque neurone représente un cluster de caractéristiques similaires.
- En trouvant le neurone le plus proche des caractéristiques LBP extraites, l'application peut classifier l'image en fonction des clusters de la SOM.

3. Classification

- La combinaison des LBP et de la SOM permet de classifier l'image en fonction des motifs de texture qu'elle contient.
- La prédiction et la classe montrent que l'image a été correctement classifiée, indiquant une bonne performance de l'application pour cette tâche spécifique.

4.7 Discussion

La mise en place d'un système de reconnaissance de l'iris combinant LBP et SOM présente de nombreux défis techniques liés à la qualité des images, à la précision du prétraitement, à l'extraction des caractéristiques et à l'intégration des deux techniques. Le défi majeur rencontré était lié à l'entraînement de notre modèle qui, malgré la puissance de calcul de notre machine, a requis un temps considérable.

Notons que plusieurs méthodes peuvent être utilisées pour la reconnaissance de l'iris. Chaque technique a ses propres avantages et inconvénients. Les LBP combinés avec les SOM offrent un bon compromis entre précision, temps de reconnaissance, et complexité computationnelle.

Bien que les résultats obtenus soient prometteurs, des améliorations peuvent être envisagées pour renforcer la robustesse du modèle face aux variations extrêmes des conditions de capture. Une approche potentielle pourrait être d'intégrer un réseau de neurones convolutifs (CNN) pour améliorer l'extraction des caractéristiques. De plus, l'utilisation des techniques de prétraitement plus avancées, telles que la normalisation adaptative, pourrait réduire encore davantage le taux d'erreur dans des environnements à faible luminosité.

Conclusion

Nous avons exposé notre système de reconnaissance par l'iris basé sur la méthode LBP et les cartes auto-organisatrices de Kohonen (SOM), entraîné sur la base de données Casia_IrisV4 et testé sur la base de données Casia_IrisV1. Les résultats démontrent que l'adoption d'une approche combinant la méthode LBP et les réseaux de neurones SOM produit des résultats significativement positifs en termes de rapidité et de précision. De plus, la méthode LBP combinée au SOM est une stratégie simple et efficace. En conclusion, notre approche combinant les méthodes LBP et SOM a montré une amélioration significative en termes de précision et de rapidité par rapport aux autres méthodes de reconnaissance de l'iris. Cette méthode pourrait être implémentée dans des systèmes de sécurité à grande échelle, tels que les contrôles d'accès biométriques dans les aéroports ou les systèmes bancaires sécurisés. Pour aller plus loin, l'intégration des techniques d'apprentissage profond, comme les réseaux de neurones convolutifs, pourraient encore améliorer la robustesse du modèle face à des conditions de capture difficiles. Ces travaux ouvrent la voie à des systèmes de reconnaissance de l'iris plus performants et plus rapides, adaptés aux besoins croissants de sécurité dans le monde numérique d'aujourd'hui.

CONCLUSION GENERALE

Dans cette étude, nous avons développé un système de reconnaissance de l'iris en combinant les Local Binary Patterns (LBP) et les Self-Organizing Maps (SOM). Cette approche, conçue pour répondre à nos objectifs spécifiques, s'est révélée particulièrement efficace.

Tout d'abord, nous avons atteint une précision de 99% grâce à la capacité des LBP à extraire des caractéristiques de texture locale de manière compacte et discriminante. Cette technique compare chaque pixel avec ses voisins pour générer des descripteurs binaires, résumant ainsi les informations de texture de l'iris avec une grande exactitude. Associée à la SOM, qui regroupe ces caractéristiques en clusters en préservant les relations topologiques, nous avons renforcé la capacité du système à identifier correctement les motifs distincts de l'iris, réduisant ainsi les erreurs de détection et augmentant le taux de réussite global à 99%.

Ensuite, la robustesse aux variations a été assurée en utilisant l'approche LBP-SOM, qui s'est montrée capable de gérer efficacement les variations de luminosité, de position et d'angle. La SOM, par son principe d'organisation non supervisée, permet de visualiser et d'analyser la structure des données d'une manière qui reste fiable même dans des conditions variées, garantissant ainsi une reconnaissance robuste.

Enfin, l'efficacité computationnelle a été démontrée par un temps de reconnaissance moyen de 0,06 seconde, ce qui prouve que notre système est adapté aux environnements nécessitant des réponses en temps réel. La simplicité et la rapidité de calcul des LBP, combinées à la capacité de classification non supervisée de la SOM, font de cette approche un choix optimal pour des systèmes biométriques en temps réel. En répondant à ces défis, cette étude ne se limite pas à améliorer les performances des systèmes actuels de reconnaissance de l'iris. Elle ouvre également la voie à de nouvelles applications dans des domaines où la sécurité biométrique est essentielle.

En conclusion, la combinaison des LBP et de la SOM offre une solution équilibrée entre simplicité, efficacité et robustesse pour la classification des images d'iris. Cette approche est particulièrement adaptée aux applications biométriques où des décisions rapides et précises sont requises, tout en offrant une visualisation claire et intuitive de la structure des données. De plus,

cette méthode peut être étendue et adaptée à d'autres domaines nécessitant une reconnaissance et une classification basées sur des motifs de texture.

RÉFÉRENCES BIBLIOGRAPHIQUES

- [1] Mohamed A, Mohamed M. A. Abou-El-Soud Marwa M. Eid, « Automated algorithm for iris detection and code generation », *Publ. Int. Conf. Commun. Electron. Syst.*, 2009.
- [2] A. Nigam, V. Krishna, A. Bendale, et P. Gupta, « Iris recognition using block local binary patterns and relational measures », in *IEEE International Joint Conference on Biometrics*, sept. 2014, p. 1-6. doi: 10.1109/BTAS.2014.6996263.
- [3] M. Riek et R. Böhme, « The costs of consumer-facing cybercrime: an empirical exploration of measurement issues and estimates† », *J. Cybersecurity*, vol. 4, n° 1, p. ty004, janv. 2018, doi: 10.1093/cybsec/tyy004.
- [4] National Research Council (US) Whither Biometrics Committee, *Biometric Recognition: Challenges and Opportunities*. Washington (DC): National Academies Press (US), 2010. Consulté le: 8 février 2025. [En ligne]. Disponible sur: <http://www.ncbi.nlm.nih.gov/books/NBK219896/>
- [5] J. G. Daugman, « Biometric personal identification system based on iris analysis », US5291560A, 1 mars 1994 Consulté le: 10 février 2025. [En ligne]. Disponible sur: <https://patents.google.com/patent/US5291560A/en>
- [6] A. K. Jain, A. Ross, et S. Prabhakar, « An introduction to biometric recognition », *IEEE Trans. Circuits Syst. Video Technol.*, vol. 14, n° 1, p. 4-20, janv. 2004, doi: 10.1109/TCSVT.2003.818349.
- [7] J. Daugman, « How iris recognition works », *IEEE Trans. Circuits Syst. Video Technol.*, vol. 14, n° 1, p. 21-30, janv. 2004, doi: 10.1109/TCSVT.2003.818350.
- [8] D. Maltoni, D. Maio, A. K. Jain, et J. Feng, *Handbook of Fingerprint Recognition*. Cham: Springer International Publishing, 2022. doi: 10.1007/978-3-030-83624-5.
- [9] A. K. Jain, P. Flynn, et A. A. Ross, Éd., *Handbook of Biometrics*. Boston, MA: Springer US, 2008. doi: 10.1007/978-0-387-71041-9.

- [10] W. Zhao, R. Chellappa, P. J. Phillips, et A. Rosenfeld, « Face recognition: A literature survey », *ACM Comput Surv*, vol. 35, n° 4, p. 399-458, déc. 2003, doi: 10.1145/954339.954342.
- [11] J. G. Daugman, « High confidence visual recognition of persons by a test of statistical independence », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, n° 11, p. 1148-1161, nov. 1993, doi: 10.1109/34.244676.
- [12] T. Kinnunen et H. Li, « An overview of text-independent speaker recognition: From features to supervectors », *Speech Commun.*, vol. 52, n° 1, p. 12-40, janv. 2010, doi: 10.1016/j.specom.2009.08.009.
- [13] R. Plamondon et G. Lorette, « Automatic signature verification and writer identification — the state of the art », *Pattern Recognit.*, vol. 22, n° 2, p. 107-131, janv. 1989, doi: 10.1016/0031-3203(89)90059-9.
- [14] « Biometric Solutions for Secure Identity (2023) | Thales ». Consulté le: 9 février 2025. [En ligne]. Disponible sur: <https://www.thalesgroup.com/en/markets/digital-identity-and-security/government/biometrics>
- [15] A. Hilal, « Système d'identification à partir de l'image d'iris et détermination de la localisation des informations », oct. 2013. Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/Syst%C3%A8me-d'identification-%C3%A0-partir-de-l'image-d'iris-Hilal/8bde14c3d6fac869ba38b1f637f8f75555bea825>
- [16] « Institute of Automation, Chinese Academy of Sciences | Semantic Scholar ». Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://www.semanticscholar.org/topic/Institute-of-Automation%2C-Chinese-Academy-of/356096>
- [17] R. P. Wildes, « Iris recognition: an emerging biometric technology », *Proc. IEEE*, vol. 85, n° 9, p. 1348-1363, sept. 1997, doi: 10.1109/5.628669.
- [18] P. V. C. Hough, « Method and means for recognizing complex patterns », US3069654A, 18 décembre 1962 Consulté le: 12 février 2025. [En ligne]. Disponible sur: <https://patents.google.com/patent/US3069654A/en>

- [19] R. O. Duda et P. E. Hart, « Use of the Hough transformation to detect lines and curves in pictures », *Commun. ACM*, vol. 15, n° 1, p. 11-15, janv. 1972, doi: 10.1145/361237.361242.
- [20] « Iris Segmentation and Normalization using Daugman ' s Rubber Sheet Model », 2016. Consulté le: 10 février 2025. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/Iris-Segmentation-and-Normalization-using-Daugman-%E2%80%99/47f4bd93c1fe3275fcd90c999e82d8aa5ff4c7c6>
- [21] T. Ahonen, A. Hadid, et M. Pietikainen, « Face Description with Local Binary Patterns: Application to Face Recognition », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 28, n° 12, p. 2037-2041, déc. 2006, doi: 10.1109/TPAMI.2006.244.
- [22] T. Kohonen, « Self-organized formation of topologically correct feature maps », *Biol. Cybern.*, vol. 43, n° 1, p. 59-69, 1982, doi: 10.1007/BF00337288.
- [23] C. D. Manning, P. Raghavan, et H. Schütze, « Introduction to Information Retrieval », Higher Education from Cambridge University Press. Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://www.cambridge.org/highereducation/books/introduction-to-information-retrieval/669D108D20F556C5C30957D63B5AB65C>
- [24] R. O. Duda, P. E. Hart, et D. G. Stork, *Pattern Classification*. John Wiley & Sons, 2012.
- [25] B. Bariza, H. Larbi, et H. Salim, « RESEAUX DE NEURONES ARTIFICIELS POUR LA MODELISATION DU DOSAGE DU COAGULANT DANS LES STATIONS DE TRAITEMENTS DES EAUX DE SURFACE A FAIBLE TURBIDITE », 2012. Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/RESEAUX-DE-NEURONES-ARTIFICIELS-POUR-LA-DU-DOSAGE-A-Bariza-Larbi/eee1dc160bb7eac280e22832c6436d5e263339e8>
- [26] D. E. Rumelhart, G. E. Hinton, et R. J. Williams, « (1986) D. E. Rumelhart, G. E. Hinton, and R. J. Williams, Learning internal representations by error propagation, Parallel Distributed Processing: Explorations in the Microstructures of Cognition, Vol. I, D. E. Rumelhart and J. L. McClelland (Eds.) Cambridge, MA: MIT Press, pp. 318-362 », avr. 1988, doi: 10.7551/mitpress/4943.003.0128.
- [27] S. S. Haykin, *Neural networks : a comprehensive foundation*. Upper Saddle River, N.J. : Prentice Hall, 1999. Consulté le: 8 février 2025. [En ligne]. Disponible sur: http://archive.org/details/neuralnetworksco0000hayk_2ed

- [28] S. Pereira, A. Pinto, V. Alves, et C. A. Silva, « Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images », *IEEE Trans. Med. Imaging*, vol. 35, n° 5, p. 1240-1251, mai 2016, doi: 10.1109/TMI.2016.2538465.
- [29] L. Gao, S. Xiao, C. Hu, et Y. Yan, « Hyperspectral Image Classification Based on Fusion of Convolutional Neural Network and Graph Network », *Appl. Sci.*, vol. 13, n° 12, p. 7143, juin 2023, doi: 10.3390/app13127143.
- [30] « 18 The Perceptron: A Probabilistic Model for Information Storage and Organization (1958) », in *Ideas That Created the Future: Classic Papers of Computer Science*, MIT Press, 2021, p. 183-190. Consulté le: 9 février 2025. [En ligne]. Disponible sur: <https://ieeexplore.ieee.org/document/9357585>
- [31] A. Gangwar et A. Joshi, « DeepIrisNet: Deep iris representation with applications in iris recognition and cross-sensor iris recognition », in *2016 IEEE International Conference on Image Processing (ICIP)*, sept. 2016, p. 2301-2305. doi: 10.1109/ICIP.2016.7532769.
- [32] A. Krizhevsky, I. Sutskever, et G. E. Hinton, « ImageNet classification with deep convolutional neural networks », *Commun. ACM*, vol. 60, n° 6, p. 84-90, mai 2017, doi: 10.1145/3065386.
- [33] « (PDF) Prediction of the earthquake magnitude by time series methods along the East Anatolian Fault, Turkey », *ResearchGate*, févr. 2025, doi: 10.1007/s12145-021-00636-z.
- [34] T. Kohonen, *Self-Organizing Maps*. Springer Science & Business Media, 2001.
- [35] « Fig II.2: Structure d'une carte auto-organisatrice. La structuration... », *ResearchGate*. Consulté le: 10 février 2025. [En ligne]. Disponible sur: https://www.researchgate.net/figure/Structure-dune-carte-auto-organisatrice-La-structuration-topologique-de-la-couche_fig2_344618247
- [36] G. Santos et E. Hoyle, « A fusion approach to unconstrained iris recognition », *Pattern Recognit. Lett.*, vol. 33, n° 8, p. 984-990, juin 2012, doi: 10.1016/j.patrec.2011.08.017.
- [37] J. G. Daugman, « High confidence visual recognition of persons by a test of statistical independence », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, n° 11, p. 1148-1161, nov. 1993, doi: 10.1109/34.244676.

- [38] W. W. Boles et B. Boashash, « A human identification technique using images of the iris and wavelet transform », *IEEE Trans. Signal Process.*, vol. 46, n° 4, p. 1185-1188, avr. 1998, doi: 10.1109/78.668573.
- [39] L. Ma, T. Tan, Y. Wang, et D. Zhang, « Personal Identification Based on Iris Texture Analysis », *IEEE Trans Pattern Anal Mach Intell*, vol. 25, n° 12, p. 1519-1533, déc. 2003, doi: 10.1109/TPAMI.2003.1251145.
- [40] Z. Zhao et A. Kumar, « Towards More Accurate Iris Recognition Using Deeply Learned Spatially Corresponding Features », in *2017 IEEE International Conference on Computer Vision (ICCV)*, oct. 2017, p. 3829-3838. doi: 10.1109/ICCV.2017.411.
- [41] S. Minaee et A. Abdolrashidi, « DeepIris: Iris Recognition Using A Deep Learning Approach », *ArXiv*, juill. 2019, Consulté le: 8 février 2025. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/DeepIris:-Iris-Recognition-Using-A-Deep-Learning-Minaee-Abdolrashidi/eac77fce2408d87c257e1a0dae976a907862cf40>
- [42] M. Y. Shams, M. Z. Rashad, O. Nomir, et R. M. El-Awady, « Iris Recognition Based on LBP and Combined LVQ Classifier », *Int. J. Comput. Sci. Inf. Technol.*, vol. 3, n° 5, p. 67-78, oct. 2011, doi: 10.5121/ijcsit.2011.3506.
- [43] T. Ojala, M. Pietikainen, et T. Maenpaa, « Multiresolution gray-scale and rotation invariant texture classification with local binary patterns », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, n° 7, p. 971-987, juill. 2002, doi: 10.1109/TPAMI.2002.1017623.
- [44] S. Liao, X. Zhu, Z. Lei, L. Zhang, et S. Z. Li, « Learning Multi-scale Block Local Binary Patterns for Face Recognition », S.-W. Lee et S. Z. Li, Éd., in *Lecture Notes in Computer Science*, vol. 4642. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, p. 828-837. doi: 10.1007/978-3-540-74549-5_87.
- [45] M. Pietikäinen, A. Hadid, G. Zhao, et T. Ahonen, « Computer Vision Using Local Binary Patterns », in *Computational Imaging and Vision*, vol. 40. London: Springer London, 2011. doi: 10.1007/978-0-85729-748-8.
- [46] M. Duan, K. Li, C. Yang, et K. Li, « A hybrid deep learning CNN–ELM for age and gender classification », *Neurocomputing*, vol. 275, p. 448-461, janv. 2018, doi: 10.1016/j.neucom.2017.08.062.

- [47] L. L. Chambino, J. S. Silva, et A. Bernardino, « Multispectral Facial Recognition: A Review », *IEEE Access*, vol. 8, p. 207871-207883, 2020, doi: 10.1109/ACCESS.2020.3037451.
- [48] K. Hernandez-Diaz, F. Alonso-Fernandez, et J. Bigun, « Periocular Recognition Using CNN Features Off-the-Shelf », in *2018 International Conference of the Biometrics Special Interest Group (BIOSIG)*, sept. 2018, p. 1-5. doi: 10.23919/BIOSIG.2018.8553348.
- [49] « (PDF) Multimodal Biometric System Iris and Fingerprint Recognition Based on Fusion Technique », ResearchGate. Consulté le: 10 février 2025. [En ligne]. Disponible sur: https://www.researchgate.net/publication/340511996_Multimodal_Biometric_System_Iris_and_Fingerprint_Recognition_Based_on_Fusion_Technique
- [50] S. Arora et M. P. S. Bhatia, « A Computer Vision System for Iris Recognition Based on Deep Learning », in *2018 IEEE 8th International Advance Computing Conference (IACC)*, déc. 2018, p. 157-161. doi: 10.1109/IADCC.2018.8692114.
- [51] A. Sallam, H. A. Amery, S. Al-Qudasi, S. Al-Ghorbani, T. H. Rassem, et N. M. Makbol, « Iris Recognition System Using Convolutional Neural Network », in *2021 International Conference on Software Engineering & Computer Systems and 4th International Conference on Computational Science and Information Management (ICSECS-ICOCSIM)*, août 2021, p. 109-114. doi: 10.1109/ICSECS52883.2021.00027.
- [52] J. Zhou et T. Komuro, « Recognizing Fall Actions from Videos Using Reconstruction Error of Variational Autoencoder », in *2019 IEEE International Conference on Image Processing (ICIP)*, sept. 2019, p. 3372-3376. doi: 10.1109/ICIP.2019.8803671.
- [53] P. E. Hart, « How the Hough transform was invented [DSP History] », *IEEE Signal Process. Mag.*, vol. 26, n° 6, p. 18-22, nov. 2009, doi: 10.1109/MSP.2009.934181.
- [54] K. Nabil, D. Farid, et B. Naceredine, « Identification basée sur le code d'iris ».
- [55] Q. Tian, H. Qu, L. Zhang, et R. Zong, « Personal Identity Recognition Approach Based on Iris Pattern », 2011. doi: 10.5772/17110.
- [56] « MATLAB ». Consulté le: 12 février 2025. [En ligne]. Disponible sur: <https://www.mathworks.com/products/matlab.html>

- [57] J. Canny, « A Computational Approach to Edge Detection », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-8, n° 6, p. 679-698, nov. 1986, doi: 10.1109/TPAMI.1986.4767851.