

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

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

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية العلوم
Faculté de Technologie

قسم الإلكترونيك
Département d'Electronique



Mémoire de Projet de Fin d'Études

Présenté par

BINTOU SAIDOU SOULEYMANE

Pour l'obtention du diplôme de Master en Electronique
Spécialité : Instrumentation

Thème

Contrôle d'Accès par Vérification Parentale à base d'Images

Promoteurs :

Djamel Bouchaffra, Directeur de Recherche, CDTA, Alger.
Fayçal YKHLEF, Maître de Recherche A, CDTA, Alger.

Co-promoteur :

Farid YKHLEF, Professeur, Université Saad Dahleb, Blida.

Membre du jury :

Président : Pr. Benselama Zoubir

Examineur : Pr. Abderrezak Guessoum

REMERCIEMENTS

Tout d'abord, je remercie ALLAH Sobhanou de m'avoir accordé la volonté et le courage d'entreprendre et d'achever ce travail.

D'emblée, je dois une reconnaissance très profonde à mes promoteurs et encadreurs Pr Djamel BOUCHAFFRA, Directeur de recherche au CDTA et Dr. Fayçal YKHLEF, Maitre de Recherche A au CDTA, pour avoir orienté et enrichi mon travail. Je les remercie pour leurs disponibilités, leurs précieux conseils, et leurs confiances malgré mes connaissances assez légères dans le domaine de l'intelligence artificielle.

Je remercie tout le personnel et les chercheurs du Centre de Développement des Technologies Avancées (C.D.T.A), et en particulier ceux de la Division Architecture des Systèmes et Multimédias (ASM) pour leur accueil et leur soutien.

Je tiens également à remercier mon co-encadreur Dr. Farid YKHLEF, Professeur au niveau de l'Université SAAD DAHLEB, pour sa disponibilité ses conseils et son sens d'écoute et d'échange.

DEDICACE

Alhamdullilah, je remercie ALLAH.

À Ma chère mère, que nulle dédicace ne puisse exprimer mes sincères sentiments pour son encouragement continu, son soutien, ses souhaits, en témoignage de mon profond amour et respect pour ses sacrifices. Que dieu le tout puissant te protège et te garde à mes côtés.

À Mon père, qui a toujours prié pour moi, ma soutenu et ma épauler pour que je puisse atteindre mes objectifs. Que dieu te protège et te garde pour moi. Que ce travail soit le témoignage de ma gratitude et de mon affection.

A mes frères et sœurs pour leurs encouragements permanents, et leur soutien moral.

Merci d'être toujours là pour moi.

RESUME

ملخص: تقدم هذه الرسالة العلمية تطوير نظام مبتكر لنظام التحكم في الدخول يتحقق من القرابة بناءً على الخصائص الوجهية المستمدة من الصور. الهدف الرئيسي هو تصميم طريقة قوية ودقيقة لتحديد العلاقة بين الأفراد. يمتلك هذا النظام تطبيقات في مجالات الأمان السكني، والتحكم في الدخول إلى المناطق المقيدة، والتعرف داخل بيئة عائلية. تستخدم الأطروحة شبكات التعرف التلقائي بالتحويلات المتداخلة (CNN) لتصنيف التشابه والاختلاف بين أفراد العائلة. حققت الطريقة المقترحة دقة تبلغ 91.75% على قاعدة بيانات KinFaceW-II.

مفاتيح البحث: التحقق من القرابة، شبكات التعرف التلقائي بالتحويلات المتداخلة (CNN)، نظام التحكم في الدخول، صور الوجه.

Résumé :

Ce mémoire présente le développement d'un système de contrôle d'accès innovant basé sur la vérification de la parenté à partir d'images. L'objectif principal est de concevoir une méthode robuste et précise pour déterminer la présence ou l'absence de lien de parenté entre deux individus en utilisant des caractéristiques faciales. Cette méthode trouve des applications dans différents domaines tels que la sécurité résidentielle, l'accès à des zones restreintes ou sensibles, ainsi que dans des scénarios d'identification au sein d'un environnement familial. Le mémoire met en œuvre une approche reposant sur l'apprentissage profond des caractéristiques en exploitant les capacités des réseaux de neurones convolutifs (CNN). Un modèle de CNN est utilisé pour extraire les caractéristiques faciales à partir de paires d'images et effectuer une classification en distinguant les similarités et les différences entre les membres d'une même famille. La méthode proposée a été évaluée sur la base de données KinFaceW-II, obtenant un taux de bonne classification de 91.75%.

Mots clés : Vérification de la parenté, CNN, contrôle d'accès, images faciales.

Abstract:

This thesis presents the development of an innovative access control system that verifies kinship based on facial characteristics from images. The main objective is to design a robust and accurate method to determine the relationship between individuals. This system has applications in residential security, access control to restricted areas, and identification within a family environment. The thesis utilizes convolutional neural networks (CNN) to classify similarities and differences among family members. The proposed method achieved an accuracy of 91.75% on the KinFaceW-II database.

Keywords: Parentage verification, CNN, access control, facial images.

LISTE DES ACRONYMES ET ABREVIATIONS

ANN: *Artificial neural network*

AUC: *Area under the curve*

ADN: *acide désoxyribonucléique*

CNN: *Convolutional neural network*

DDML: *Discriminative Deep Metric Learning*

DDMML: *Discriminative Deep Multi-Metric Learning*

FIW: *Families in the wild*

KinFace-II: *Kinship face in the wild II*

LBP: *Local binary pattern*

LFW: *labeled face in the wild*

MLP: *Multi layer perceptron*

NRML: *Neighborhood repulsed metric learning*

ROC : *Receiver operating characteristic*

TABLE DES MATIERES

Résumé	(i)
Liste d'abréviations et acronymes	(ii)
Remerciements	(iii)
Dédicaces	(iv)
Table des matières	(v)
Liste des tableaux	(vi)
Liste des figures	(vii)

INTRODUCTION GENERALE

CHAPITRE 1 : VERIFICATION DE LA PARENTE ET CONTROLE D'ACCES

1.1	Introduction	9
1.2	Concepts de base de la vérification de la parenté	9
1.3	Concepts de base pour le contrôle d'accès	17
1.4	Conclusion	21

CHAPITRE 2 : SYSTEME DE VERIFICATION DE LA PARENTE A BASE DU CNN

2.1	Introduction	22
2.2	Réseaux de neurones convolutifs	22
2.3	Choix de paramètres	28
2.4	Méthodes de régularisation	29
2.5	La validation croisée	30
2.6	Méthode proposée	30
2.7	Conclusion	35

CHAPITRE 3 : RESULTATS EXPERIMENTAUX

3.1	Introduction	37
3.2	Langage et logiciels de développement	37
3.3	Implémentation de la méthode proposée	39
3.4	Résultats et discussions	41
3.5	Conclusion	46

CONCLUSIONS ET TRAVAUX FUTURES

4.1	Conclusions	47
4.2	Travaux futurs	47

LISTE DES FIGURES

Figure 1.1: Problèmes liées à variation d'âge et sexe	12
Figure 1.2: Mauvaise qualité des images et différence d'âge trop élevé [7].	13
Figure 1.3: Changement de pose, d'angle de prise et variation d'éclairage [4].	13
Figure 2.1: Réseau de neurones artificiels [37]	23
Figure 2.2: Réseau de neurone convolutif (CNN) [3].....	26
Figure 2.3: Pooling avec un filtre 2x2 et un pas de 2 [37]	27
Figure 2.4 : Représentation graphique de la fonctionnalité Relu [3]	28
Figure 2.5 : Architecture du modèle proposé	31
Figure 2.6 : Configuration de notre modèle	32
Figure 2.7: Schéma générale du système de contrôle d'accès par de vérification de parenté.....	33
Figure 3.1 : Pycharm	38
Figure 3.2: Quelques images de la base de données KinFaceW-II [48].....	40
Figure 3.3: Différents types de relation existante dans la base de données KinFaceW-II [48]	40
Figure 3.4 : Courbe d'accuracy de l'entraînement et de la validation	42
Figure 3.5: Courbe de perte de l'entraînement et de la validation.....	43
Figure 3.6: Matrice de confusion de notre modèle.....	43
Figure 3.7: Courbe ROC pour l'évaluation de performance de notre système.....	44
Figure 3.8 : Aperçu de l'interface	45
Figure 3.9: Exemple utilisant une paire d'image de relation vrai.....	45
Figure 3.10 : Exemple utilisant une paire d'image de relation inexistante.....	46

LISTE DES TABLEAUX

Tableau 2-1 : Matrice de confusion dans le cas binaire.....	35
Tableau 3-1 : Evaluation des performances du modèle	44

Introduction Générale

Dans le monde actuel, où la sécurité et la protection des informations sensibles sont primordiales, les systèmes de contrôle d'accès jouent un rôle crucial. Traditionnellement, ces systèmes reposent sur des méthodes telles que l'utilisation de cartes d'identité, de codes PIN ou de mots de passe pour avoir accès à un lieu. Cependant, ces approches peuvent être contournées ou falsifiées, ce qui soulève la nécessité de développer des méthodes plus avancées et plus fiables pour garantir l'intégrité des systèmes de contrôle d'accès. Ainsi, une solution efficace et révolutionnaire pour assurer la sécurité au sein d'un environnement familial serait un contrôle d'accès basé sur la vérification de la parenté à partir d'images faciales. Cette approche réduirait considérablement les risques de vol et d'intrusion, offrant un sentiment de sécurité accru.

Dans ce contexte, nous développerons un système de vérification automatique de la parenté pour le contrôle d'accès, par exemple, à l'entrée d'une maison. Ce système vérifie la parenté en comparant l'image faciale de la personne avec celles des propriétaires du lieu. Si un lien de parenté est établi, la personne est autorisée à accéder au lieu, sinon l'accès lui est refusé.

En se concentrant sur les caractéristiques partagées par les membres d'une même famille, cette approche ouvre de nouvelles perspectives pour des applications de sécurité et d'identification dans les environnements familiaux, les frontières et les services de police.

La vérification de la parenté à partir d'images présente de nombreux défis, tels que les variations d'âge, de sexe, d'origine ethnique, les ressemblances entre des personnes sans lien de parenté réel, et les différences d'attributs faciaux entre des personnes de la même famille. Ces difficultés constituent des défis à relever pour mener à bien notre étude. Afin d'optimiser notre approche, nous nous appuyons sur les récents développements en matière d'apprentissage profond des caractéristiques grâce aux réseaux de neurones convolutifs (Convolutional Neural Network - CNN). Ces réseaux sont capables d'apprendre et d'extraire automatiquement des représentations significatives à partir d'images, permettant ainsi de capturer des informations pertinentes pour la vérification de la parenté.

Notre méthodologie rigoureuse combine une revue approfondie de la littérature scientifique sur la vérification de la parenté et l'apprentissage profond, des expérimentations pratiques et une évaluation des performances du système proposé. Les résultats obtenus nous permettront d'évaluer l'efficacité de l'approche basée sur la vérification de la parenté et de discuter de son potentiel dans le contexte des systèmes de contrôle d'accès.

Ce mémoire est divisé en plusieurs parties. Le premier chapitre présente les notions générales sur le contrôle d'accès et la vérification de la parenté, ainsi qu'un aperçu des travaux de recherche antérieurs portant sur la vérification de la parenté à partir d'images faciales. Le deuxième chapitre passe en revue les concepts clés de l'apprentissage profond et des réseaux de neurones convolutifs (CNN), en détaillant notre approche méthodologique et les choix techniques effectués. Enfin, le troisième chapitre présente les résultats expérimentaux obtenus.

Chapitre 1 : Vérification de la parenté et contrôle d'accès

1.1 Introduction

Le test ADN (acide désoxyribonucléique) est le moyen le plus fiable pour la vérification de la parenté, mais en raison des coûts élevés et de la durée du processus, il ne peut pas être utilisé dans de nombreuses situations telles que le contrôle d'accès d'un lieu [1]. C'est pour cela qu'il faut faire recours à d'autres moyens tels que la vérification de la parenté à partir d'image de visage. Ainsi l'utilisation de la vérification de la parenté comme moyen de contrôle pour accéder à certains lieux ou ressource pourrait être une solution efficace. En outre la vérification de parenté à partir d'image rencontre plusieurs difficultés telles qu'une mauvaise qualité de l'image, un environnement inapproprié (éclairage sombre, la pose, l'angle de vision...). Tous ces défis augmentent considérablement les difficultés pour résoudre le problème de la vérification de la parenté. Ce chapitre est divisé en deux grandes parties. Dans la première partie, nous définirons les concepts de base de la vérification de la parenté qui nous permettront de mieux cerner la suite de notre approche. Ensuite la deuxième partie sera consacrée aux notions sur le contrôle d'accès et son lien avec la vérification de la parenté.

1.2 Concepts de base de la vérification de la parenté

1.2.1 Qu'est-ce que la parenté ?

Dans la tradition occidentale, le terme "parenté" est souvent associé à la notion de "consanguinité" et fait référence à un lien biologique. En effet, la parenté est un système d'organisation sociale qui englobe les personnes considérées comme biologiquement apparentées (liées par le sang) ou celles ayant acquis le statut de parents par le biais du mariage, de l'adoption ou d'autres rituels. La parenté régule les comportements au sein des différentes branches familiales [2].

1.2.2 Vérification de la parenté

La vérification de la parenté vise à déterminer de manière efficace et précise l'existence d'une relation de parenté entre deux individus. Au cours des dernières années, cette vérification s'est principalement concentrée sur l'étude de la similarité et de l'apprentissage profond des

caractéristiques du visage, bien que le test ADN demeure le moyen le plus fiable de vérifier la parenté [3]. Il existe quatre principaux types de relations de parenté : les relations père-fille (Father- Daughter : F-D), mère-fils (Mother-Son : M-S), père-fils (Father-Son : F-S) et mère-fille (Mother-Daughter : M-D). Récemment, d'autres types de relations de parenté sont apparus, comme la relation entre les grands-parents et les petits-enfants [4].

1.2.3 Parenté dans la vision par ordinateur

La vérification d'images est une tâche de vision par ordinateur qui vise à identifier divers éléments présents dans des images et/ou des vidéos. L'objectif de la vérification de la parenté est de déterminer si une paire d'images de visages de deux personnes est liée par une relation de parenté ou non. En effet, il s'agit d'entraîner une machine à reconnaître la relation de parenté entre une paire de visages, en se basant sur des caractéristiques extraites des images faciales.

Le premier ensemble de données contenant des paires d'images de parents a été collecté par Fang et al. [5] en 2010, et depuis lors, plus d'une dizaine de bases de données d'images et/ou de vidéos ont été créées. Ces bases de données sont utilisées dans de nombreuses applications potentielles dans le monde réel.

1.2.4 Applications

Avec les progrès technologiques, tels que les appareils photo numériques de haute qualité, les appareils mobiles et Internet, les images numériques deviennent une nouvelle marque d'identité d'une personne. Ainsi, l'étude de la parenté à travers les visages est devenue un sujet intéressant d'une grande importance scientifique. Il a un grand impact sur l'application réelle et de nombreux domaines [6].

Nous résumons les domaines d'application possibles comme suit :

- Filtrage des demandes d'asile,
- Retrouver des membres de la famille disparus, des victimes ou des criminels par les forces de l'ordre,
- Traite/trafic d'enfants au niveau des frontières,
- Analyse des médias sociaux,
- Identification de parents à partir d'une collection de photos d'images par exemples les albums photos,

La vérification de la parenté englobe plusieurs aspects liés à la sécurité. Les parents de personnes identifiées, comme étant une menace pour la sécurité, peuvent être identifiés en utilisant un cadre de vérification automatique de la parenté. La détermination automatique des informations de parenté peut également être utilisée pour renforcer les capacités de reconnaissance automatique des visages en se basant sur les caractéristiques de parenté comme biométrie douce. En effet, la vérification de la parenté dans les vidéos est un domaine de recherche peu exploré, mais il peut s'avérer très utile dans divers contextes tels que la sécurité, la surveillance et le contrôle de l'immigration. Par exemple, pour le contrôle des frontières, les vidéos de surveillance peuvent être utilisées pour confirmer le lien de parenté entre un adulte et un enfant, ce qui permet de prévenir le trafic illégal d'enfants. La vérification de la parenté pourrait être une solution efficace pour renforcer la sécurité dans nos maisons afin d'éviter les intrusions et les vols [4].

1.2.5 Problèmes et challenges

Fondamentalement, les problèmes et défis auxquels la vérification de la parenté fait face sont divisés en deux catégories : les problèmes directs (lié à la parenté elle-même) et les problèmes indirects (lié à l'environnement de la base de données) [4]. En ce qui concerne les problèmes directs, de nombreuses études antérieures ont identifié trois points majeurs, à savoir :

- La difficulté de vérifier la similarité des caractéristiques et de choisir les caractéristiques faciales pertinentes pour déterminer s'il existe une relation parents-enfants. Il est nécessaire de décrire et d'extraire les caractéristiques les plus héritées dans une famille afin de réaliser un système robuste de vérification de la parenté.
- Les variations d'âge et de sexe des membres de la famille rendent la tâche plus compliquée car en réalité pour des personnes du même intervalle d'âge et de même sexe, la vérification est plus facile. Des fois même à l'œil nu la ressemblance est remarquable (figure1.1).

De plus, généralement les traits de visage de personnes d'une même famille montrent une perception visuelle plus similaire que celle des personnes sans lien de sang. Néanmoins, ils peuvent présenter une grande dissemblance alors que les visages de personnes n'ayant aucun lien de parenté peuvent se ressembler.

D'autre part, nous avons les problèmes indirects qui sont principalement liés à la qualité de l'image du visage. En effet les images peuvent être capturées dans des environnements inappropriés ou dans de mauvaises conditions et cela peut présenter plusieurs désavantages et difficultés comme illustrées dans la figure 1.1 et la figure 1.2. Nous pouvons citer :

- La prise de l'image avec une mauvaise posture ne permet pas d'extraire convenablement les caractéristiques du visage,
- L'illumination du lieu de prise d'image et l'angle de vision de la caméra peuvent fournir des images de qualité réduites ou même floutés,
- Le port d'accessoires (casquettes, lunettes...) aussi est un frein la vérification car de fois il ne permet pas d'extraire les caractéristiques du visage.

Ces complications caractérisent la vérification de la parenté comme un problème large et difficile. En effet tous ces problèmes sont aussi des défis a relevés pour permettre de vérifier de la parenté dans de bonnes conditions.



Figure 1.1: Problèmes liées à variation d'âge et sexe

Sur la Figure 1.1, les 3 premières paires d'images de parent-enfant sont dans un intervalle d'âge élevé et de sexe différents, et les 3 autre paires d'images de parent-enfant juste en dessous sont dans un intervalle d'âge restreint et de même sexe.

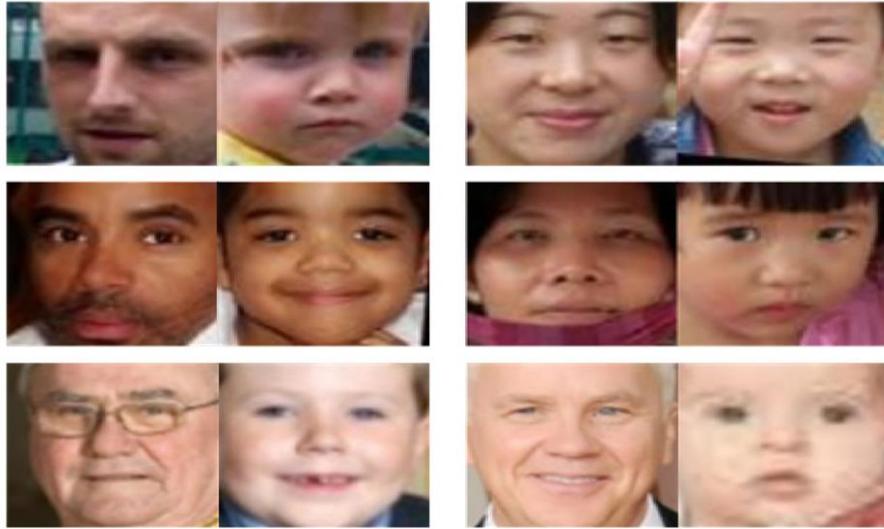


Figure 1.2: Mauvaise qualité des images et différence d'âge trop élevé [7].



Figure 1.3: Changement de pose, d'angle de prise et variation d'éclairage [4].

1.2.6 Travaux connexes

Avant le début des recherches de la vérification de la parenté dans le domaine de la vision par ordinateur, la parenté a été largement étudiée dans le domaine de la psychologie [8] [9] [10] [11]. Les travaux de la vérification de la parenté peuvent être divisés en trois groupes en fonction du processus d'extraction et d'apprentissage des caractéristiques : (1) extraction de caractéristiques (artisanale), (2) apprentissage métrique et (3) apprentissage en profondeur. Les premières méthodes de vérification de la parenté se concentrent sur l'extraction de caractéristiques au niveau des repères faciaux tels que les yeux et le nez. Les descripteurs fabriqués à la main sont HOG (Histogram of oriented gradients), LBP (Local binary pattern) et Gabor. Plus tard, des

méthodes d'apprentissage de métriques sont proposées pour exploiter les métriques (de distance) en maximisant les distances inter-classes et en minimisant les distances intra-classes. Plus récemment, l'apprentissage en profondeur a été proposé pour apprendre simultanément des fonctionnalités et des métriques. L'apprentissage profond est basé sur les CNN qui sont capables d'apprendre les fonctionnalités intégrées efficaces à partir des données brutes d'origines [1] [12] [13] [14] [15]. Sur la base de différents scénarios d'application, la recherche vérification de la parenté a été étendue à de multiples sujets complémentaires [16] [17] [18] [19] [20] [21].

1.2.6.1 Vérification de la parenté base sur l'apprentissage des caractéristiques

Fang et al. [5] ont été les premiers à proposer la vérification de la parenté à partir d'images faciales en 2010. Ils ont utilisé un ensemble de caractéristiques de bas niveau pour leur approche. Pour constituer leur base de données, ils ont effectué une recherche contrôlée en ligne afin de collecter des images du visage frontal de 150 paires de personnages publics et de célébrités. Cette base de données a été nommée Cornell KinFace. Leur méthode a atteint une précision de classification de 70,67% sur cette base de données.

Plus récemment, Lopez et al [22] en 2016 ont proposé de faire de la prédiction en utilisant la distance de chrominance. Ils ont proposé d'utiliser la métrique de la distance de chrominance entre chaque paire d'images de visage comme le score de confiance. Leur résultat a été testé sur les deux bases de KinFaceW. La précision de classification obtenue par leur méthode de notation simple sur KinFaceW-I atteint environ 70 %. Plus important encore, dans l'ensemble de données KinFaceW-II la précision de classification de leur méthode atteint 80%.

Le travail de Moudjahid et al. [23] en 2018 présente une nouvelle approche qui permet de fusionner efficacement les informations locales et globales sur les traits du visage de divers descripteurs. La précision de classification atteinte par leur méthode sur KinFaceW-I et KinfaceW-II est d'environ 88%.

Goyal et al. [24] en 2020 ont proposé une nouvelle approche de vérification de la parenté faciale basée sur l'excentricité nommée EKV (Eccentricity based Kinship verification) pour montrer la puissance des régions dominantes du visage pour la vérification de la parenté. Le taux de bonne reconnaissance a atteint une précision compétitive sur plusieurs bases de données comme Cornell kinface 86.27%, KinFaceW-I 90.30% , KinFaceW-II 90.15%, UB KinFace 85.03%, TsKinFace 90.85%, FIW 87.87% .

Comme deuxième titre dans cette section nous montrons et décrivons les méthodes de pointe qui apprennent une distance métrique par une stratégie d'apprentissage métrique proposée pour la tâche de vérification de la parenté.

1.2.6.2 Vérification de la parenté base sur l'apprentissage métrique

Lu et al. [25] en 2014 ont construit deux bases de données de parenté, nommées KinFaceW-I et KinFaceW-II, à partir des recherches sur Internet, ou des images de visages ont été capturées dans des conditions non contrôlées. Ils ont proposé une nouvelle approche d'apprentissage de métrique (distance) repoussé par le voisinage nommée NRML (Neighborhood repulsed metric learning) pour la vérification de la parenté faciale. Pour montrer une meilleure utilisation de la description de caractéristiques multiples et d'extraire des informations intégrales, ils ont proposé une méthode NRML multi-vues (MNRML) pour calculer une distance métrique commune pour combiner des caractéristiques multiples dans un sous-espace de fusion afin d'améliorer la performance de la vérification de la parenté faciale. Ils ont mené des expériences de vérification de parenté sur deux autres ensembles de données : Cornell KinFace [26] et UB KinFace [27]. Les méthodes NRML et MNRML qu'ils ont proposée sont plus performantes que les autres méthodes d'apprentissage métrique comparées pour les tâches de vérification de parenté.

Zhou et al. [28] en 2019 ont proposé une nouvelle approche d'apprentissage métrique pour la vérification de la parenté nommée KML (Kernel based metric learning) avec un modèle de réseau neuronal profond DNN (deep neural network) fusionné. Pour évaluer l'efficacité de la méthode de vérification de la parenté, ils ont réalisé des expériences sur quatre jeux de données largement utilisés : KinFaceW-I, KinFaceW-II, Cornell KinFace, et UB KinFace. Le taux de bonne reconnaissance de la méthode KML est comme le suivant 82.8% sur KinFaceW-I, 85.7% sur KinFaceW-II, 81.4% sur Cornell KinFace, et 75.5% sur UB KinFace.

Le travail de Bessaoudi et al. [29] en 2019 a proposé un cadre basé sur l'apprentissage métrique par tenseur (tenseur d'ordre élevé) pour la conception d'images faciales. Ils ont proposé une nouvelle analyse discriminante basée sur l'information latérale multilinéaire (MSIDA) pour traiter la réduction et la classification semi-supervisée des projections de sous-espaces multilinéaires. Ils ont comparé les performances de vérification obtenues par l'approche proposée avec les méthodes de leur état de l'art sur la base de données Bosphorus 3D. Le meilleur taux de vérification de leur approche a atteint 92.12%.

Dornaika et al. [30] en 2020 a introduit un nouveau schéma qui extrait les traits profonds du visage pour la vérification de la parenté. L'approche fusionne une sélection efficace des caractéristiques et une projection de l'information des données proéminentes orientée vers la parenté. Dans leur travail, les caractéristiques faciales sont obtenues par les CNN profonds pré-entraînés VGG-F et VGG-Face, qui ont été essentiellement proposés pour la classification de groupes d'objets et d'identités, respectivement. Le taux de bonne reconnaissance du cadre proposé sur les bases de données KinFace-I et KinFace-II est de 84.55%, 86.90% respectivement. Dans le titre qui suit, nous avons présente les méthodes basées essentiellement sur des CNN profonds au problème de la vérification de la parenté.

1.2.6.3 Vérification de la parenté base sur l'apprentissage profond

Lu et al. [31] ont proposé une approche DDML (Discriminative Deep Metric Learning) pour entrainer un réseau neuronal profond qui peut apprendre un groupe de sous-espaces de transformations non linéaires hiérarchiques pour projeter des images faciales dans le même espace de caractéristiques implicites, dans lequel la métrique de chaque paire positive est minimisée et celle de chaque paire négative est maximisée respectivement. Ensuite, en 2017, ils ont mis au point une méthode efficace d'apprentissage multi-métrique profond DDMML (Discriminative Deep Multi-Metric Learning) [32] pour combiner les caractéristiques de chaque paire pour apprendre ensemble plusieurs réseaux neuronaux, ce qui permet d'augmenter la corrélation entre les différentes caractéristiques de chaque échantillon, la métrique de chaque paire positive est diminuée et celle de chaque paire négative est maximisée, respectivement. Deux ensembles de données de parente sont utilisés pour évaluer leur méthode (KinFaceW-I, KinFaceW-II). Ils ont eu comme taux de bonne classification (accuracy) avec la méthode DDML 72.25% sur la base KinFaceW-I, et 78.25% sur KinFaceW-II, et pour la méthode DDMML 83.5% KinFaceW-I, 84.3% KinFaceW-II.

Yan et al. [14] ont présenté une approche pour la vérification de la parenté des visages, qui utilise un réseau d'attention pour se concentrer sur l'obtention d'informations discriminantes des régions locales du visage. Ils ont proposé une méthode auto-supervisée pour orienter le réseau d'attention. En outre, ils incluent de manière aléatoire un masque dans cinq régions de chaque visage pour aider le réseau à se concentrer sur l'obtention d'informations plus efficaces dans ces groupes de régions. Ils ont testé leur méthode sur deux bases de données et ils ont eu comme résultat 82.6 % sur KinFaceW-I, et 92% sur la base KinFaceW-II.

Zhang et al. [33] montrent que la plupart des approches existantes pour la vérification de la parenté faciale peuvent être subdivisées en méthodes d'apprentissage superficiel basées sur les caractéristiques artisanales et en méthodes d'apprentissage profond basées sur les CNN. Par conséquent, une approche de CNN adversatif de données basée sur l'identification de la famille (AdvKin), principalement axée sur les traits de parenté efficaces, a été proposée pour les deux types de bases de données (vérification de la parenté faciale à grande échelle et à petite échelle). Ils ont testé leur méthode sur les deux bases de données KinFaceW-I et KinFaceW-II et ils ont eu comme résultat 78.7% sur le jeu de data KinFaceW-I et 88.0 % sur KinFaceW-II.

1.3 Concepts de base pour le contrôle d'accès

1.3.1 Définition

Au niveau le plus élémentaire, le contrôle d'accès est un moyen de réguler l'entrée dans un lieu ainsi que le moment de cette entrée. Il englobe le contrôle physique de l'accès, où la personne qui souhaite pénétrer dans le lieu peut être un employé, un sous-traitant ou un visiteur, et peut se déplacer à pied, en conduisant un véhicule ou en utilisant un autre moyen de transport. Le lieu lui-même peut être un site, un bâtiment, une pièce ou même simplement une armoire.

Lorsque nous faisons référence à un système de contrôle d'accès physique, nous parlons généralement d'un système de sécurité électronique. Ce système utilise souvent un identifiant, tel qu'un badge d'accès, pour autoriser les individus à accéder à certaines zones. En enregistrant qui est entré où et quand, il est capable de fournir des données et des graphiques précieux pour vous aider à suivre l'utilisation de vos bâtiments et sites [34].

1.3.2 Les types de contrôle d'accès

Il existe cinq différents types de contrôle d'accès [35].

- **Contrôle d'accès manuel**

Pour le contrôle d'accès manuel, des individus sont chargés de sécuriser des points d'entrée spécifiques, tels que des portiers, des stewards ou des agents du service clientèle. Leur rôle est d'identifier les personnes souhaitant entrer dans les locaux et de décider, selon des critères prédéfinis, si elles sont autorisées à le faire ou non. Par exemple, une personne présentant un billet avant d'entrer dans une salle de concert. Cette méthode est utilisée aux points d'accès très

fréquentés, tels que les cinémas ou les théâtres, où il est difficile d'obtenir des informations préalables de la part des personnes et où l'identification n'est pas requise.

- **Contrôle d'accès mécanique**

Le contrôle d'accès mécanique s'utilise pour sécuriser un point d'accès. Un exemple courant serait notamment une serrure cylindrique avec une clé appropriée, généralement utilisée dans les maisons ou les garages.

- **Contrôle d'accès électronique**

Pour les bâtiments ayant des exigences de sécurité avancées. Le contrôle d'accès électronique s'utilise pour sécuriser les points d'accès. Pour ces types d'accès, il faut présenter à un lecteur une carte, une puce ou d'autres badges avec les informations d'identification correctes pour qu'une personne puisse passer. Cela permet également d'enregistrer les personnes qui sont passées par la zone et à quel moment. Il existe deux types de systèmes d'accès électroniques : les systèmes autonomes et les systèmes en ligne.

- **Contrôle d'accès mécatronique**

Une combinaison de systèmes électroniques et mécaniques s'utilise également pour offrir une sécurité supplémentaire. Dans ce cas, le système électronique vérifie d'abord la carte/le code/les autres supports utilisés. Et ce n'est qu'après avoir passé ce contrôle qu'une clé peut être utilisée sur la serrure mécanique pour ouvrir la porte. Ce type de combinaison s'utilise généralement dans les bureaux ayant des exigences de sécurité élevées. Mais aussi dans les immeubles résidentiels privés et les salles de serveurs.

- **Contrôle d'accès physique**

Les systèmes d'accès physique jouent un rôle important dans la sécurité. Voici quelques exemples de systèmes d'accès physique :

Barrières de capteurs, Tourniquets mi-hauteur, Des tourniquets pleine hauteur, Tourniquets tripodes, Portes tournantes, Verrouillages de sécurité [35].

1.3.3 Histoire du contrôle d'accès

En effet, la forme la plus ancienne (et assez simple) de contrôle d'accès est souvent considérée comme une intervention humaine : par exemple, l'utilisation de personnes agissant comme gardiens pour protéger les bâtiments ou d'autres zones contre un accès non autorisé. Cependant, à mesure que les colonies se développaient, le besoin de systèmes de contrôle d'accès plus sophistiqués est devenu évident.

La première serrure à clé connue aurait été inventée il y a plus de 6 000 ans – et un exemple précoce a été découvert dans les ruines de Ninive, la capitale de l'ancienne Assyrie, vers 600 avant notre ère.

Les premiers contrôles d'accès porte électroniques ont été développés dans les années 1960 et utilisaient des cartes perforées pour donner accès aux bâtiments. Ces systèmes ont rapidement été remplacés par des cartes à bande magnétique, plus durables et plus faciles à utiliser.

Bien sûr, ces contrôles d'accès portes électroniques utilisaient quelque chose de plus qu'une serrure pour sécuriser la porte : ce qui nous amène à l'invention des lecteurs de contrôle d'accès et de l'interphone.

Dans les années 1980 et 1990, de nouveaux systèmes d'interphone numérique ont été introduits, offrant une qualité audio et vidéo plus claire et un meilleur contrôle de l'accès.

Les lecteurs d'accès, qui sont utilisés pour accorder ou refuser l'accès à un bâtiment ou à une zone spécifique, ont également été développés à peu près en même temps que les interphones de porte. Les premiers lecteurs d'accès utilisaient des cartes à bande magnétique, qui étaient glissées pour accorder l'accès.

Dans les années 1990, le développement de la technologie RFID radio frequency identification en anglais a permis la création du contrôle d'accès porte sans contact. Les cartes et badges d'accès RFID pouvaient être utilisés pour accorder l'accès aux bâtiments sans avoir besoin d'un contact physique avec la serrure.

Finalement, au XXI^e siècle (en 2008 pour être exact), le premier interphone IP a été inventé par 2N : conduisant à un tout nouveau niveau de contrôle d'accès porte avec des fonctionnalités avancées qui n'avaient jamais été vues auparavant.

Les événements horribles du 11 septembre ont eu un impact profond sur le monde tel que nous le connaissons – et le contrôle d'accès n'en est pas exempt. En conséquence, les contrôles d'accès porte ont commencé à mettre davantage l'accent sur des méthodes de vérification d'accès plus sûres et sur la cybersécurité.

De nos jours, bien que le principe du contrôle d'accès porte soit resté le même (c'est-à-dire restreindre l'accès), la technologie a évolué à un niveau complètement nouveau. Les contrôles d'accès porte sont utilisés dans un large éventail d'applications, de la sécurisation des maisons et des entreprises à la protection des informations précieuses dans les systèmes numériques. Le contrôle d'accès évolue à un rythme sans précédent, et continue d'évoluer, avec l'introduction de nouvelles technologies telles que les serrures intelligentes et les systèmes de sécurité intégrés.

Les contrôles d'accès porte ont encore évolué depuis le développement des systèmes de contrôle d'accès biométriques. Les systèmes biométriques offrent divers choix, du contrôle par badge, mobile, commande vocale, empreinte digitale, allant jusqu'à la reconnaissance faciale pour ne citer que ça [34].

1.3.4 Définition et principe de fonctionnement du contrôle d'accès par vérification de la parenté

Le contrôle d'accès par vérification de la parenté est un système qui permet de gérer et de contrôler qui rentre dans un lieu précis et s'il est autorisé à y accéder. Ce système se base sur la vérification de lien de parenté pour donner l'autorisation. S'il existe un lien de parenté l'accès est accepté sinon il est refusé.

Le processus de contrôle d'accès se déroule en trois étapes : l'authentification d'une personne via les caractéristiques extraites de son visage afin de déterminer l'existence d'un lien de parenté, le contrôle des autorisations qui lui sont attribuées puis la validation ou non de l'accès ; enfin, le suivi de ses déplacements.

- **Authentification**

Premièrement, les données permettant d'identifier les personnes dont l'accès est autorisé sont collectées dans le système de contrôle c'est-à-dire les images de visages des propriétaires du lieu par exemple.

Au moment de la présentation d'une personne, l'image de son visage est alors capturée et le système compare les données qui lui sont soumises avec celles présentes dans la base de données. Grâce à cette opération, l'existence d'une relation de parenté entre la personne et les propriétaires peut être défini.

- **Autorisation**

Le système de contrôle d'accès par vérification de la parenté à partir d'image facial compare les informations qui lui sont présentées avec celles présentes dans sa base de données et décide d'autoriser ou de refuser l'accès. Si la personne identifiée est autorisée à accéder à la zone sécurisée, alors son accès est validé.

- **Traçabilité**

Chaque accès peut être enregistré, donc il est possible de suivre le flux des personnes à l'intérieur des locaux de la propriété.

Ainsi, il serait possible de connaître l'identité et le nombre de personnes ayant eu accès à des locaux sensibles ou réservés. Le contrôle est instantané et efficace.

1.4 Conclusion

Ce chapitre donne un aperçu des notions essentielles pour bien comprendre le contrôle d'accès et la vérification de la parenté à partir d'images faciales. Outre les définitions, la première partie présente les contributions, les défis, les problèmes ainsi que les travaux connexes dans le domaine de la vérification de la parenté. Les travaux présentés sont divisés en trois catégories en fonction des méthodes suivantes : les méthodes basées sur des caractéristiques artisanales, les méthodes basées sur des caractéristiques d'apprentissage de métrique et celles basées sur l'apprentissage de caractéristiques profondes.

Dans la deuxième partie, nous abordons le contrôle d'accès et nous donnons un aperçu des différents types de contrôle d'accès, ainsi que du fonctionnement d'un système de contrôle d'accès basé sur la vérification de la parenté. En effet, le contrôle d'accès par vérification de la parenté consiste à vérifier s'il existe un lien de parenté entre deux individus, permettant ainsi de contrôler l'accès à un lieu où seuls les individus apparentés ont le droit d'entrer.

Dans le prochain chapitre, nous présenterons quelques notions sur les réseaux de neurones convolutionnels (CNNs) ainsi que la méthodologie à suivre pour la conception.

Chapitre 2 : Système de vérification de la parenté à base du CNN

2.1 Introduction

Ce chapitre est divisé en deux grandes sections. Dans la première partie de ce chapitre nous expliquerons ce que c'est que les réseaux de neurones en général et en particulier les CNNs, les différentes couches du CNN et leur fonctionnement. Ensuite, dans la deuxième partie nous nous intéressons à la méthodologie suivie pour la mise en place de notre système de contrôle par vérification de la parenté.

2.2 Réseaux de neurones convolutifs

2.2.1 Qu'est-ce qu'un réseau de neurone ?

Les réseaux de neurones, également appelés réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés, font partie de l'apprentissage automatique et jouent un rôle central dans les algorithmes d'apprentissage profond. Ils tirent leur nom et leur structure de l'inspiration du fonctionnement du cerveau humain, imitant la façon dont les neurones biologiques échangent des signaux. Les ANN sont composées de couches nodales, comprenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie comme illustré sur la figure 2.1. Chaque nœud, ou neurone artificiel, est connecté à d'autres nœuds et possède des poids et des seuils associés. Si la sortie d'un nœud dépasse la valeur de seuil spécifiée, le nœud est activé et transmet des données à la couche suivante du réseau. Sinon, aucune donnée n'est transmise à la couche suivante du réseau [36].

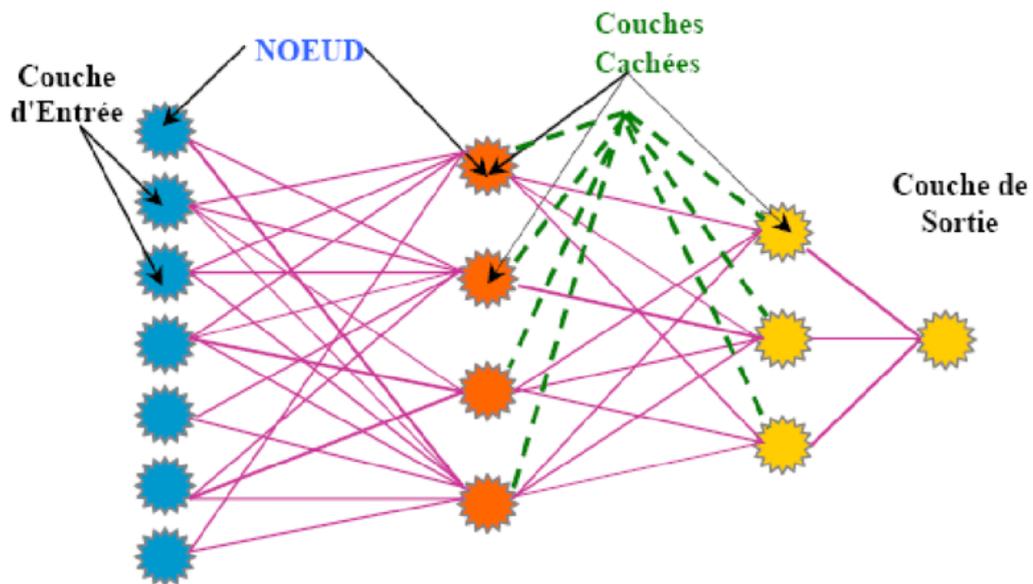


Figure 2.1: Réseau de neurones artificiels [37]

Les réseaux de neurones s'appuient sur des données d'entraînement pour apprendre et améliorer leur précision au fil du temps. Cependant, une fois que ces algorithmes d'apprentissage sont réglés avec précision, ils constituent des outils puissants en informatique et en intelligence artificielle, nous permettant de classer et de regrouper des données à une vitesse élevée. Les tâches de reconnaissance vocale ou de reconnaissance d'images peuvent prendre quelques minutes plutôt que des heures par rapport à l'identification manuelle par des experts humains. L'un des réseaux de neurones le plus connu est l'algorithme de recherche de Google.

2.2.2 Types de réseaux de neurones

Les réseaux de neurones peuvent être classés en différents types, qui sont utilisés à des fins différentes. Bien qu'il ne s'agisse pas d'une liste exhaustive des types de réseaux de neurones, la liste ci-dessous est représentative des types les plus courants de réseaux de neurones que vous rencontrerez dans les cas d'utilisation les plus fréquents [38] :

- Le perceptron est le plus ancien réseau de neurones, créé par Frank Rosenblatt [38] en 1958.
- Les réseaux de neurones à propagation avant, ou perceptrons multicouches MLP (Multi Layer Perceptron), sont ceux sur lesquels porte principalement cet article. Ils sont constitués d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie. Si ces réseaux de neurones sont aussi communément appelés MLP, il est important de noter qu'ils sont en fait composés de neurones sigmoïdes, et non pas de perceptrons,

car la plupart des problèmes du monde réel sont non linéaires. Les données sont généralement introduites dans ces modèles pour les entraîner, et ils constituent la base de la vision par ordinateur, du traitement du langage naturel et d'autres réseaux de neurones.

- Les réseaux de neurones convolutifs (CNN) sont similaires aux réseaux à propagation avant, mais ils sont généralement utilisés pour la reconnaissance d'images, la reconnaissance de formes et/ou la vision par ordinateur. Ces réseaux exploitent les principes de l'algèbre linéaire, en particulier la multiplication des matrices, pour identifier les motifs dans une image.
- Les réseaux de neurones récurrents (RNN) sont identifiés par leurs boucles de rétroaction. Ces algorithmes d'apprentissage sont principalement exploités lorsqu'on utilise des données de séries chronologiques pour faire des prédictions sur des résultats futurs, comme les prédictions boursières ou les prévisions de ventes.

2.2.3 Qu'est-ce qu'un réseau de neurone convolutif ?

Les CNN désignent une sous-catégorie des ANN. Cependant, les CNN sont spécialement conçus pour traiter des images en entrée. Leur architecture est alors plus spécifique : elle est composée de deux blocs principaux.

- Le premier bloc est la caractéristique distinctive de ce type de réseau de neurones, car il fonctionne comme un extracteur de caractéristiques. Pour cela, il utilise des opérations de filtrage par convolution pour effectuer une correspondance de modèles (template matching). La première couche applique plusieurs noyaux de convolution pour filtrer l'image et générer des "feature maps" (cartes de caractéristiques). Ensuite, ces cartes de caractéristiques sont normalisées à l'aide d'une fonction d'activation et/ou redimensionnées. Ce processus peut être répété plusieurs fois : les cartes de caractéristiques obtenues sont filtrées à nouveau avec de nouveaux noyaux, ce qui produit de nouvelles cartes de caractéristiques à normaliser et redimensionner, et cela peut être répété encore et encore. Finalement, les valeurs des dernières cartes de caractéristiques sont concaténées pour former un vecteur. Ce vecteur constitue la sortie du premier bloc et l'entrée du second bloc.
- Le deuxième bloc n'est pas spécifique à un CNN. En réalité, on le retrouve à la fin de tous les réseaux de neurones utilisés pour la classification. Les valeurs du vecteur en entrée sont transformées à l'aide de plusieurs combinaisons linéaires et fonctions d'activation pour

produire un nouveau vecteur en sortie. Ce dernier vecteur contient autant d'éléments qu'il y a de classes : l'élément i représente la probabilité que l'image appartienne à la classe i . Chaque élément est donc compris entre 0 et 1, et la somme de tous les éléments vaut 1. Ces probabilités sont calculées par la dernière couche de ce bloc (et donc du réseau), qui utilise une fonction d'activation logistique (pour la classification binaire) ou une fonction d'activation softmax (pour la classification multi-classe). Comme pour les réseaux de neurones classiques, les paramètres des couches sont déterminés par rétropropagation du gradient : l'entropie croisée est minimisée pendant la phase d'entraînement. Cependant, dans le cas des CNN, ces paramètres représentent spécifiquement les caractéristiques des images. Dans la prochaine partie, nous examinerons les différentes couches du CNN [39].

2.2.4 Architecture du CNN

Un CNN est simplement une composition de plusieurs couches de convolution, de pooling, de correction ReLU et de couches fully-connected. Chaque image en entrée subit donc plusieurs étapes de filtrage, de réduction et de correction, pour finalement être représentée par un vecteur. Dans le cas de la classification, ce vecteur contient les probabilités d'appartenance aux différentes classes. Tous les CNNs doivent commencer par une couche de convolution et se terminer par une couche fully-connected. Les couches intermédiaires peuvent être empilées de différentes manières, à condition que la sortie d'une couche ait la même structure que l'entrée de la couche suivante. Par exemple, une couche fully-connected, qui produit toujours un vecteur en sortie, ne peut pas être placée avant une couche de pooling, car cette dernière attend une matrice 3D en entrée. En général, un réseau de neurones empile plusieurs couches de convolution et de correction ReLU, ajoute éventuellement une couche de pooling, et répète ce schéma plusieurs fois. Ensuite, il empile des couches fully-connected. Plus le réseau de neurones comporte de couches, plus il est considéré comme "profond", ce qui correspond à la notion de Deep Learning. On distingue quatre types de couches couramment utilisées dans un CNN : la couche de convolution, la couche de pooling, la couche de correction ReLU et la couche fully-connected. La figure 2.2 illustre l'architecture d'un CNN avec toutes ces couches [40].

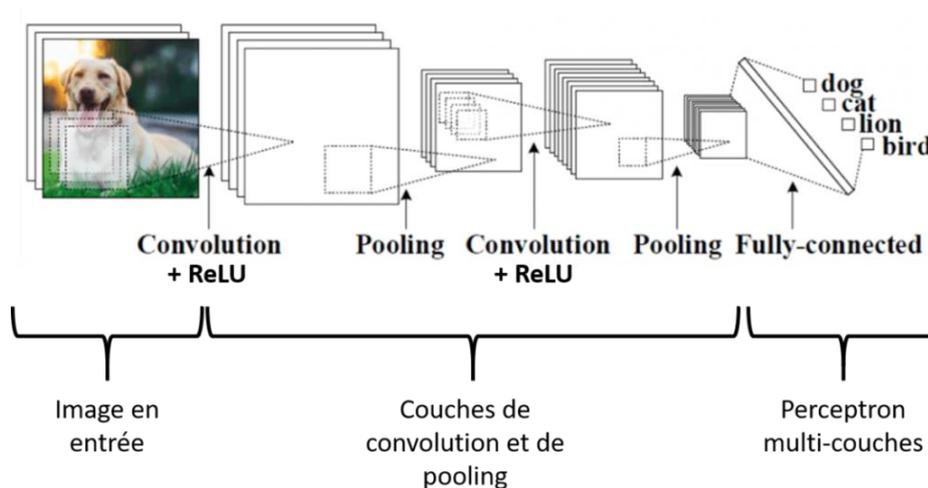


Figure 2.2: Réseau de neurone convolutif (CNN) [3].

2.2.5 Couche de convolution

La couche de convolution est l'élément clé des CNN. Son objectif est de détecter la présence d'un ensemble de caractéristiques dans les images en entrée. Pour cela, elle effectue un filtrage par convolution : le principe est de faire "glisser" une fenêtre représentant la caractéristique sur l'image et de calculer le produit de convolution entre la caractéristique et chaque région de l'image balayée. On peut considérer une caractéristique comme un filtre, les deux termes étant équivalents dans ce contexte. Trois paramètres permettent de définir la taille de la couche de convolution : la profondeur, le pas et la marge [3].

- Profondeur de la couche : nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).
- Le pas : contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
- La marge (à 0) ou zéro padding : parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zéro-padding' est le troisième hyper paramètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée.

La sortie est appelée carte de caractéristiques qui nous donne des informations sur l'image telles que les coins et les bords. Plus tard, cette carte de caractéristiques est introduite dans d'autres couches pour apprendre plusieurs autres caractéristiques de l'image d'entrée [40].

2.2.6 Couche de pooling (POOL)

L'opération de pooling vise à réduire la taille des images tout en préservant leurs caractéristiques importantes. Pour ce faire, l'image est découpée en cellules régulières et la valeur maximale de chaque cellule est conservée [56]. En général, des cellules carrées de petite taille sont utilisées afin de limiter la perte d'informations. Les options les plus courantes consistent à utiliser des cellules adjacentes de 2×2 pixels sans chevauchement ou des cellules de 3×3 pixels espacées de 2 pixels les unes des autres (avec chevauchement). À la sortie de cette opération, le nombre de cartes de caractéristiques (feature maps) reste le même, mais leur taille est considérablement réduite (Figure 2.3). La couche de pooling permet ainsi de réduire le nombre de paramètres et de calculs dans le réseau, améliorant son efficacité et évitant le sur-apprentissage.

Il est important de noter que les valeurs maximales sont repérées avec moins de précision dans les cartes de caractéristiques obtenues après le pooling par rapport à celles en entrée. Cependant, cela présente un avantage significatif. Par exemple, lorsqu'on souhaite reconnaître un chien, il n'est pas nécessaire de localiser précisément ses oreilles. Savoir qu'elles se trouvent approximativement à côté de la tête suffit généralement. Ainsi, la couche de pooling rend le réseau moins sensible à la position exacte des caractéristiques. Une légère variation dans la position ou l'orientation d'une caractéristique ne devrait pas entraîner de changement radical dans la classification de l'image [37] [40].

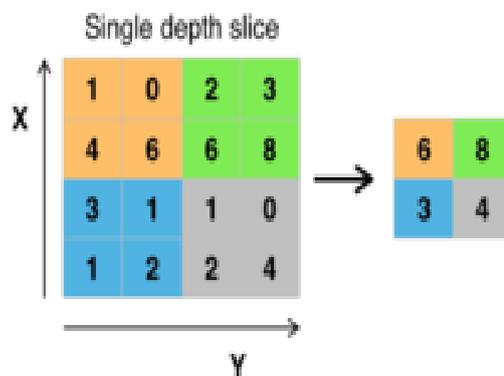


Figure 2.3: Pooling avec un filtre 2x2 et un pas de 2 [37].

2.2.7 Couches de correction (RELU)

La fonctionnalité ReLU est illustrée à la, (Figure 2.4). La couche de correction ReLU remplace donc toutes les valeurs négatives reçues en entrées par des zéros. Elle joue le rôle de fonction d'activation [40].

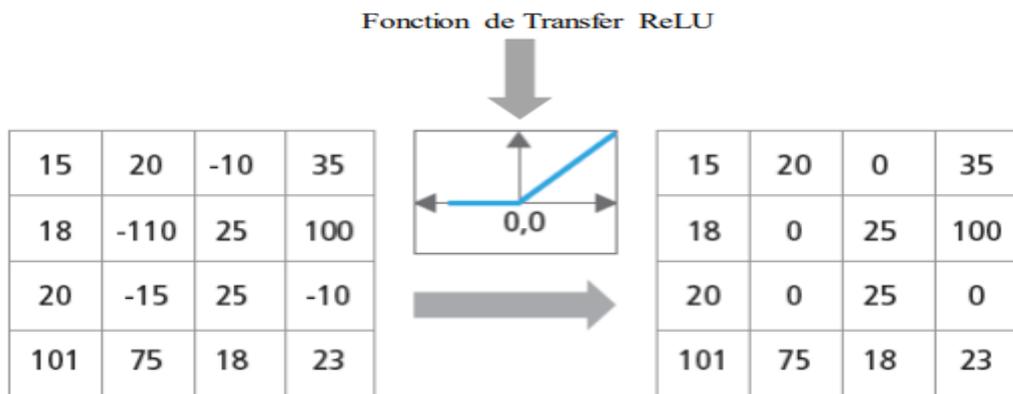


Figure 2.4 : Représentation graphique de la fonctionnalité Relu [3]

2.2.8 Couche entièrement connectée (FC)

Les cartes des caractéristiques de résultat de la couche de convolutions, pooling et ReLU fournissent au final un ensemble de caractéristiques qui seront concaténées en un vecteur de caractéristiques, appelé code CNN. Ce code CNN est ensuite branché en entrée d'une deuxième partie, constituée d'une ou de plusieurs couches entièrement connectées (FC ou fully connected) qu'on peut assimiler au perceptron multicouches. Les neurones dans une couche entièrement connectée ont des connexions vers les sorties de la couche précédente.

Le nombre de neurones de la dernière couche entièrement connectée est égal au nombre de classes. Le rôle de cette partie est donc de combiner les caractéristiques du code CNN pour classer une image.

2.3 Choix de paramètres

Les CNN utilisent plus de paramètres qu'un MLP standard. Même si les règles habituelles pour les taux d'apprentissage et des constantes de régularisation s'appliquent toujours, il faut prendre en considération les notions de nombre de filtres, leur forme et la forme du max pooling [36].

2.3.1 Nombre et forme des filtres

Comme la taille des images intermédiaires diminue avec la profondeur du traitement, les couches proches de l'entrée ont tendance à avoir moins de filtres tandis que les couches plus proches de la sortie peuvent en avoir davantage.

La forme des filtres est généralement choisie en fonction de l'ensemble de données. Ils peuvent être dans la gamme de 5x5, 12x12, voire 15x15 cela en fonction de la taille de la donnée.

2.3.2 Forme du Max Pooling

Les valeurs typiques sont 2x2. De très grands volumes d'entrée peuvent justifier un pooling 4x4 dans les premières couches. Cependant, le choix de formes plus grandes va considérablement réduire la dimension du signal, et peut entraîner la perte de trop d'information.

2.4 Méthodes de régularisation

Cette technique clé de machine learning vise à limiter le « surapprentissage » (overfitting) et à contrôler l'erreur de type variance pour aboutir à de meilleures performances. Il existe deux groupes de méthodes, les méthodes empiriques et les méthodes explicites [3].

2.4.1 Empirique

- **Dropout**

La méthode du dropout est utilisée pour "éteindre" les neurones aléatoirement (avec une probabilité prédéfinie, souvent un neurone sur deux) ainsi que les neurones périphériques. Ainsi, avec moins de neurones, le réseau est plus réactif et peut donc apprendre plus rapidement. À la fin de la séance d'apprentissage, les neurones "éteints" sont "rallumés" (avec leurs poids originaux). Cette technique a montré non seulement un gain dans la vitesse d'apprentissage, mais en déconnectant les neurones, on a aussi limité des effets marginaux, rendant le réseau plus robuste et capable de mieux généraliser les concepts appris.

2.4.2 Explicite

- **Taille du réseau**

La manière la plus simple de limiter le sur apprentissage est de limiter le nombre de couches du réseau et de libérer les paramètres libres (connexions) du réseau. Ceci réduit directement la puissance et le potentiel prédictif du réseau. C'est équivalent à avoir une "norme zéro".

- **Dégradation du poids**

En pratique, la régularisation s'effectue après avoir calculé la loss function. Il existe deux types de régularisation.

La régularisation L1 : La spécificité de cette régulation est de diminuer le poids des entrées aléatoires et faibles et d'augmenter le poids des entrées "importantes". Le système devient moins sensible au bruit. La régularisation L2 : (norme euclidienne) La spécificité de cette régulation est

de diminuer le poids des entrées fortes, et de forcer le neurone à plus prendre en compte les entrées de poids faible.

2.5 La validation croisée

Cette méthode consiste à diviser l'échantillon original en k échantillons, puis on sélectionne un des k échantillons comme ensemble de validation et les $(k-1)$ autres échantillons constitueront l'ensemble d'apprentissage. L'erreur est estimée en calculant un test, une mesure ou un score de performance du modèle sur l'échantillon de test, par exemple l'erreur quadratique moyenne. Puis on répète l'opération en sélectionnant un autre échantillon de validation parmi les $(k-1)$ échantillons qui n'ont pas encore été utilisés pour la validation du modèle. L'opération se répète ainsi k fois pour qu'en fin de compte chaque sous échantillon ait été utilisé exactement une fois comme ensemble de validation. La moyenne des k erreurs quadratiques moyennes est enfin calculée pour estimer l'erreur de prédiction [23].

2.6 Méthode proposée

2.6.1 Architecture du CNN proposé

La structure de base de CNN utilisée dans ce travail contient trois couches convolutives, deux couches pooling suivies d'une couche entièrement connectée (figure 2.5).

L'image en entrée doit être de taille 64×64 avec trois canaux (RVB), l'image passe d'abord à la première couche de convolution. Cette couche est composée de 16 filtres de taille $5 \times 5 \times 6$ avec une foulée de 1. Chacune de nos couches de convolution est suivie d'une fonction d'activation ReLU. Cette fonction force les neurones à retourner des valeurs positives. Ensuite on applique la couche de Maxpooling de taille 2×2 pour réduire la taille de l'image ainsi la quantité de paramètres et de calcul. Chaque filtre est de taille $5 \times 5 \times 6$. La deuxième couche convolutive filtre l'entrée de la couche précédente avec 64 noyaux de taille $5 \times 5 \times 16$. La troisième couche convolutive contient 128 noyaux de taille $5 \times 5 \times 64$. L'ensemble des opérations implique la normalisation, la remise à l'échelle et le décalage des valeurs d'entrées dès cette couche c'est pour cela que nous utilisons des couches de BatchNormalization. Après les couches convolutionnelles, une couche entièrement connectée projette les caractéristiques extraites dans un sous-espace de 640 neurones.

Pour la régularisation de notre modèle nous utilisons deux couches Dropout. La couche dropout consiste à désactiver des sorties de neurones aléatoirement avec une probabilité de 50%. La figure 2.6 illustre la configuration de notre modèle.

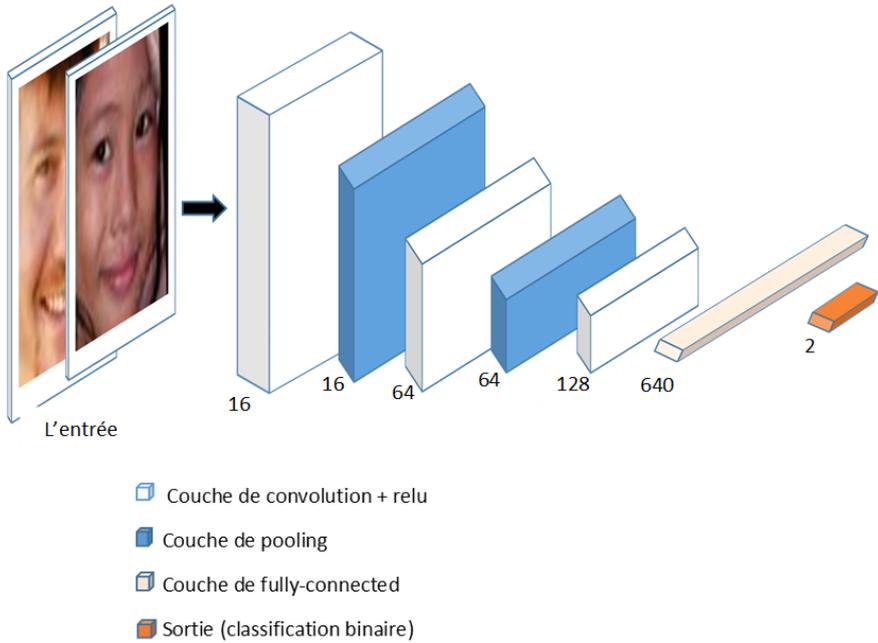


Figure 2.5 : Architecture du modèle proposé

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 60, 60, 16)	2416
batch_normalization (Batch Normalization)	(None, 60, 60, 16)	64
activation (Activation)	(None, 60, 60, 16)	0
max_pooling2d (MaxPooling2D)	(None, 30, 30, 16)	0
conv2d_1 (Conv2D)	(None, 26, 26, 64)	25664
batch_normalization_1 (Batch Normalization)	(None, 26, 26, 64)	256
activation_1 (Activation)	(None, 26, 26, 64)	0
max_pooling2d_1 (MaxPooling2D)	(None, 13, 13, 64)	0
conv2d_2 (Conv2D)	(None, 9, 9, 128)	204928
batch_normalization_2 (Batch Normalization)	(None, 9, 9, 128)	512
activation_2 (Activation)	(None, 9, 9, 128)	0
flatten (Flatten)	(None, 10368)	0
dropout (Dropout)	(None, 10368)	0
dense (Dense)	(None, 640)	6636160
batch_normalization_3 (Batch Normalization)	(None, 640)	2560
activation_3 (Activation)	(None, 640)	0
dropout_1 (Dropout)	(None, 640)	0
dense_1 (Dense)	(None, 2)	1282
activation_4 (Activation)	(None, 2)	0

=====
Total params: 6,873,842

Figure 2.6 : Configuration de notre modèle

2.6.2 Système de contrôle d'accès par vérification de la parenté à partir d'image facial

Le système de contrôle d'accès par vérification de la parenté est composé principalement de plusieurs étapes comme illustré dans la figure 2.7.

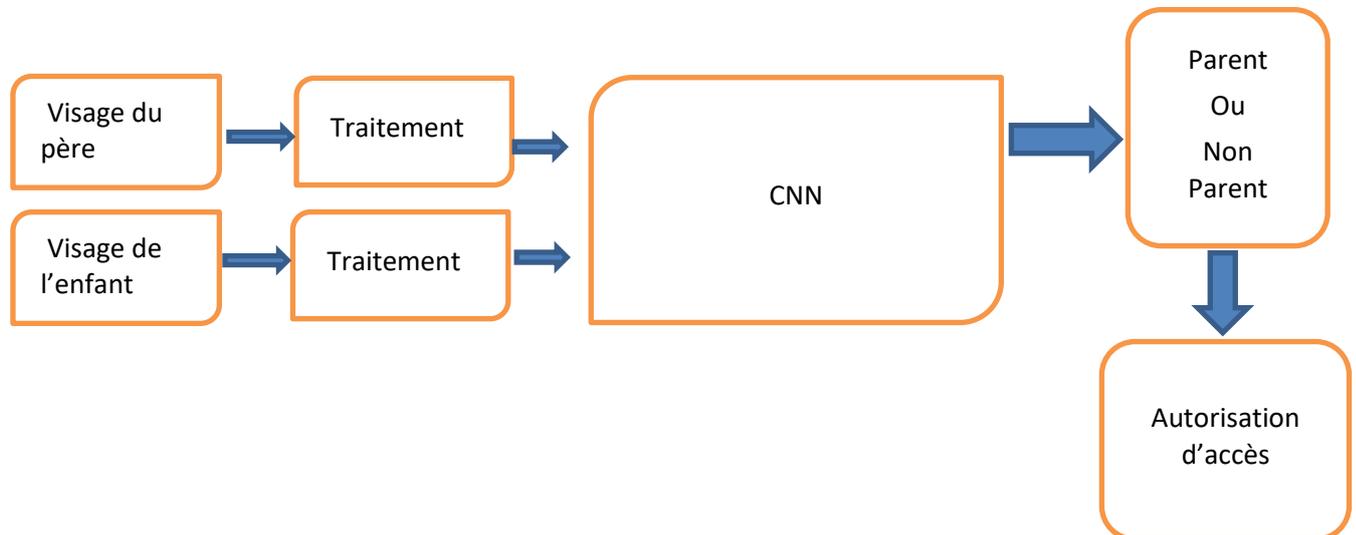


Figure 2.7: Schéma générale du système de contrôle d'accès par de vérification de parenté

2.6.2.1 L'acquisition des données

Le système se concentre sur des groupes de données faciales contenant des paires d'images de visage, des images prises dans des environnements non contrôlés sans aucune restriction. Le système reçoit en entrée deux images dont une image du parent et une image de l'enfant.

2.6.2.2 Le prétraitement

Premièrement le visage de chaque image doit être détecté s'il s'agit d'images non centré sur le visage uniquement. Pour notre part nous utiliserons des bases de données dont les images présentes seule la région du visage. Deuxièmement, le prétraitement (Preprocessing) : Ce processus symbolise l'élimination de tout ce qui n'est pas important, imparfait ou exceptionnel et peut être dispensé, le traitement est un élément de grande importance afin de localiser le visage de l'image. La zone faciale est utilisée pour vérifier la parenté en coupant le visage et en enlevant tout autre que mon visage, en particulier le fond, cheveux, lumière. S'il s'agit d'une image colorée, elle se tournera vers l'échelle de gris. Ensuite l'image du parent et l'image de l'enfant sont concaténer en une seule image. Toutes ces étapes sont réalisées dans l'ordre pour conserver les informations de base et préparer l'image à l'étape suivante.

2.6.2.3 Extraction des caractéristiques

L'extraction des propriétés (caractéristiques), ou aussi appelée représentation ou encore modélisation, nous permettra d'extraire des informations contenues dans les visages, où elles pourront être utilisées dans la prochaine étape. Pour cela nous utilisons le modèle de CNN proposé précédemment pour extraire les caractéristiques profondes contenues dans les visages. La première couche du CNN filtre l'image avec plusieurs noyaux de convolution, et renvoie des caractéristiques. Ce procédé peut être réitéré 3 fois : on filtre les caractéristiques obtenues avec de nouveaux noyaux, ce qui nous donne de nouvelles caractéristiques à normaliser et redimensionner, et qu'on peut filtrer à nouveau, et ainsi de suite. Finalement, les valeurs des dernières caractéristiques sont concaténées dans un vecteur. En effet, cette phase est considérée comme le cœur du système de vérification pour conserver les informations de base et préparer les caractéristiques des images à l'étape suivante qui est la classification.

Les caractéristiques des images étant disponibles, nous passons à la classification qui répartira les paires d'images pour les faire correspondre à une classe. Dans notre cas nous avons deux classes donc il s'agit d'une classification binaire. Les valeurs seront comprises entre 0 et 1 et la classe qui aura un grand pourcentage sera alors la classe prédite. Ainsi selon la valeur renvoyée (0 ou 1) on comprend directement s'il y'a un lien de parenté ou non.

2.6.2.4 Autorisation d'accès

Une fois la classification terminée, on récupère le résultat. Ce dernier nous permet d'autoriser ou de refuser l'accès selon l'existence ou non d'un lien de parenté.

2.6.3 Métriques d'évaluation de performance d'un système

2.6.3.1 Matrice de confusion

La première manière d'évaluer un classifieur consiste à confronter les valeurs réelles avec les valeurs prédites fournies par le modèle. L'outil privilégié est la matrice de confusion [41]. La matrice de confusion est un tableau de contingence confrontant les classes obtenues et les classes désirées pour l'échantillon suivant ces 4 variables :

- VP sont les vrais positifs, c'est-à-dire les observations qui ont été classées Positives et qui le sont réellement.

- FP sont les faux positifs, c'est-à-dire les individus classés positifs et qui sont En réalité des négatifs,
- De la même manière, les FN sont les faux négatifs et VN sont les vrais Négatifs. (Tableau 2.1).

Tableau 2-1 : Matrice de confusion dans le cas binaire

	Classe prédite	
Classe réelle	Classe 0	Classe 1
Classe 0	VP	FN
Classe 1	FP	VN

Cette matrice permet de déduire les indicateurs suivants :

- **L'accuracy (taux de bonne classification)** est une métrique de performance qui évalue la capacité d'un modèle de classification à bien prédire à la fois les individus positifs et les individus négatifs. [42]
- **La précision** mesure la précision/justesse de votre modèle. Il s'agit du rapport entre les positifs correctement identifiés (vrais positifs) et tous les positifs identifiés. La métrique de précision révèle le nombre de classes prédites qui sont correctement étiquetées.
- **La sensibilité ou le rappel** mesure la capacité du modèle à prédire les classes positives réelles. Il s'agit du rapport entre les vrais positifs prédits et ce qui a été réellement étiqueté. La métrique de rappel révèle le nombre de classes prédites correctes. [43]
- **F-mesure** est une fonction de précision et de rappel. Il est nécessaire quand vous recherchez l'équilibre entre précision et rappel.

2.6.3.2 Reiceved Operating Characteristic (ROC)

La courbe ROC ou caractéristique de performance est une mesure de performance d'un classifieur binaire. Elle représente le taux des vrais positifs en fonction de celui des faux positifs [36].

2.7 Conclusion

Ce chapitre est divisé en deux grandes parties. Dans la première partie, nous avons présenté les ANN ainsi que les CNNs et les différentes couches composant un CNN. En effet, un CNN est composé de deux parties distinctes : la mise en évidence des caractéristiques d'une image et l'analyse et l'interprétation de l'agencement de ces caractéristiques. Tout cela est rendu possible

grâce à l'opération de convolution, qui permet d'analyser les images et d'extraire des cartes de caractéristiques mettant en évidence les informations importantes de l'image. Dans la deuxième partie, nous avons détaillé l'approche que nous avons suivie pour concevoir notre système de contrôle d'accès basé sur la vérification de la parenté. Nous avons exposé les étapes et les techniques utilisées dans notre approche. Dans le prochain chapitre, nous passerons à l'implémentation de notre approche, nous effectuerons des tests et nous présenterons les résultats obtenus.

Chapitre 3 : Résultats expérimentaux

3.1 Introduction

Dans ce chapitre, nous présenterons trois sections importantes : le langage et les logiciels de développement utilisés, l'implémentation de la méthode proposée et l'interprétation des résultats obtenus.

3.2 Langage et logiciels de développement

3.2.1 Python

Python est un langage de programmation inventé par Guido van Rossum [44]. La première version de Python est sortie en 1991, et depuis lors, il est devenu l'un des langages de programmation les plus populaires et intéressants. Python est largement utilisé dans l'apprentissage de la programmation en raison de sa simplicité et de sa facilité d'apprentissage.

En tant que langage de programmation, Python est largement utilisé dans le développement logiciel. C'est un langage de haut niveau orienté objet, caractérisé par une syntaxe épurée et un code concis, ce qui permet d'accélérer le développement et de réduire les coûts. Python favorise la réutilisabilité et la modularité du code, ce qui en fait un choix populaire parmi une vaste communauté de développeurs et de programmeurs.

Python offre à la fois simplicité et puissance, permettant d'écrire des scripts simples mais aussi de travailler sur des projets plus ambitieux grâce à ses nombreuses bibliothèques. Des bibliothèques telles que TensorFlow, Keras ou Tkinter sont largement utilisées pour l'élaboration de code, notamment dans notre projet [44].

- **Tensorflow**

Il s'agit d'un frameworks de programmation pour le calcul numérique qui a été rendu Open Source par Google en Novembre 2015. Il est l'un des plus utilisés pour le Deep Learning et donc les réseaux de neurones [45].

- **Keras**

C'est une API de réseaux de neurones de haut niveau, écrite en Python et capable de fonctionner sur TensorFlow ou Theano. Il a été développé en mettant l'accent sur l'expérimentation rapide. Être capable d'aller de l'idée à un résultat avec le moins de délai possible est la clé pour faire de bonnes recherches. Il a été développé dans le cadre de l'effort de recherche du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System), et son principal auteur et mainteneur est François Chollet, un ingénieur Google [46].

- **Tkinter**

Python offre diverses options pour développer des interfaces graphiques (GUI). Parmi les plus utilisés on trouve Tkinter qu'on a utilisé pour l'implémentation de notre interface. Tkinter est la bibliothèque standard d'interface graphique pour Python. Combiné à Tkinter, Python offre un moyen rapide et facile de créer des applications graphiques.

3.2.2 Pycharm

Il existe plusieurs applications web dans lesquelles on peut développer en utilisant le langage de programmation Python. Parmi ces applications, on peut citer Spider, Jupyter Lab et PyCharm.

PyCharm est un environnement de développement intégré (IDE) utilisé spécifiquement pour la programmation en Python. Il offre de nombreuses fonctionnalités telles que l'analyse de code et un débogueur graphique (voir figure 3.1). PyCharm permet également la gestion des tests unitaires, l'intégration de logiciels de gestion de versions, et il prend en charge le développement web avec le framework Django. De plus, PyCharm offre une prise en charge complète des bibliothèques Python scientifiques telles que Matplotlib, NumPy et Anaconda. Cet IDE est particulièrement utile pour les projets de Data Science et de Machine Learning. Les graphiques interactifs facilitent la compréhension des données, et l'intégration avec des outils tels que Django, IPython et Pytest permet d'innover en proposant des solutions uniques [47].

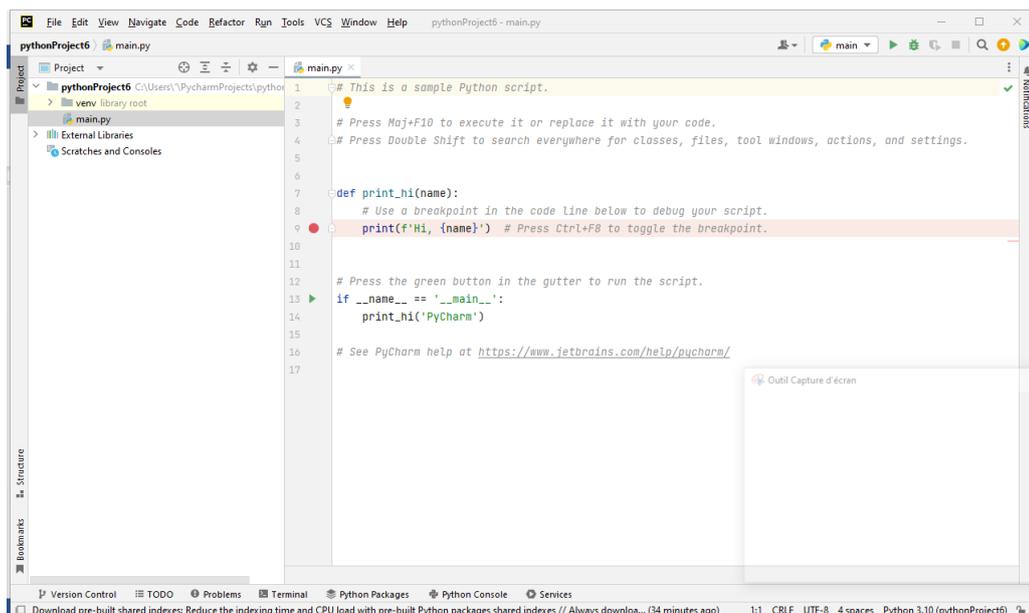


Figure 3.1 : Pycharm

3.3 Implémentation de la méthode proposée

3.3.1 Paramètres du modèle

Les paramètres utilisés pour notre modèle CNN ont été minutieusement choisis en effectuant plusieurs tests et à chaque fois en variant les valeurs des paramètres.

- La forme des filtres choisis est de 5×5 car les données en entrée sont de petite taille, donc il est mieux adapté.
- Le nombre de filtres augmente d'une couche à une autre respectivement 16, 64, 128 car pour préserver l'information en entrée, il faudrait maintenir le nombre de sorties intermédiaires (nombre d'images intermédiaire multiplié par le nombre de positions de pixel) croissant d'une couche à l'autre.
- La forme du pooling est de 2×2 prenant en compte la taille des données en entrée et aussi le choix de formes plus grandes pourrait considérablement réduire la dimension du signal, et peut entraîner la perte de trop d'information.
- Deux Dropout sont utilisés pour "éteindre" les neurones aléatoirement avec une probabilité prédéfinie d'un neurone sur deux ainsi que les neurones périphériques. Ainsi, avec moins de neurones, le réseau est plus réactif et peut donc apprendre plus rapidement.
- La régularisation L2 est utilisée afin d'effectuer un apprentissage plus rapide. Ce paramètre est réglé à 0,3.
 - Nous utilisons également l'early stopping. L'apprentissage s'arrêtera plus tôt pour prévenir le sur-apprentissage. Ce paramètre est réglé à 10.
 - La manière la plus simple de limiter le sur-apprentissage est de limiter le nombre de couches du réseau c'est pour cela nous utilisons une architecture simple.

3.3.2 Base de donnée

Pour évaluer le système proposé, nous utilisons la base de données Kinship Face in the Wild-II (KinFaceW-II). Cette base de données est composée de 1000 images faciales collectées à partir d'Internet. Les images de visages sont capturées dans des environnements non contrôlés, ce qui signifie qu'elles présentent des variations au niveau de la pose, de l'éclairage, de l'arrière-plan, de l'expression, de l'âge, de l'origine, des lunettes, de la barbe ethnique et de l'occlusion partielle.

KinFaceW-II comprend quatre types de relations de parenté : Père-Fils (FS), Père-Fille (FD), Mère-Fils (MS) et Mère-Fille (MD). Chaque type de relation contient 250 paires d'images positives et 250

paires d'images négatives. Ces paires d'images permettent de représenter les liens de parenté ainsi que des relations non parentales pour évaluer les performances du système (Figures 3.2 et 3.3).



Figure 3.2: Quelques images de la base de données KinFaceW-II [48].



Figure 3.3: Différents types de relation existante dans la base de données KinFaceW-II [48].

3.4 Résultats et discussions

3.4.1 Traitement des données

Les images de KinFaceW-II sont recadrées et alignées pour avoir une taille de 64*64 afin de supprimer les régions non faciales telles que le fond et les cheveux, et de ne conserver que la région du visage pour la vérification de la parenté. Si les images sont en couleur, nous les convertissons en images en niveaux de gris. L'ensemble de données est divisé en 5 volets et nous effectuons des expériences de quintuple validation croisée.

Pour chaque volet, toutes les paires d'images de visage sont sélectionnées pour générer des échantillons positifs et négatifs. Les échantillons positifs sont constitués des véritables paires d'images de visage (une du parent et l'autre de l'enfant), tandis que les échantillons négatifs sont constitués de fausses paires d'images de visage (une du parent et l'autre de l'enfant, mais le parent n'est pas le bon). Le nombre d'échantillons négatifs est égal au nombre d'échantillons positifs.

3.4.2 Extraction des caractéristiques et Classification

Les paires d'image sont ensuite concaténées. Le CNN proposé précédemment sera utilisé pour l'extraction des caractéristiques profondes. Pour chaque image concaténée, nous extrayons les caractéristiques des visages, qui seront par la suite concaténer et stocker dans un vecteur caractéristique.

Ensuite, s'en suit de la classification de ces vecteurs qui permet de prédire la classe de chaque paire d'image. Une fonction d'activation Softmax est utilisée à cet effet.

3.4.3 Phase d'apprentissage

Nous avons pris 1200 images pour l'apprentissage, 400 images pour la validation et 400 pour le test. Nous avons exploité les outils d'entraînement (model.fit) en langage python pour entraîner le réseau et nous avons adapté ses paramètres :

- Nombre d'époque : Une époque décrit le nombre de fois que l'algorithme passe sur la base de données entière. Dans notre travail il est à 50.
- On utilise un optimiseur SGD (Stochastic Gradient Descent ou descente du gradient stochastique) afin de réduire l'erreur total, de faciliter l'évolution du model et diminué le temps de convergence. Ces paramètres sont définis comme suit : learning rate=0.00001, momentum=0.9, decay=0.0005.

- MiniBatchSize : La taille du mini-batch utilisée pour chaque itération, dans notre travail nous avons choisi 64.
- l'Early Stopping : l'apprentissage fait appel à ce paramètre définit précédemment.

La figure 3.4 présente la courbe d'apprentissage : Précision et perte lors des itérations d'apprentissage et de validation. L'accuracy de l'apprentissage et de la validation augmente avec le nombre d'époque. Ceci reflète qu'à chaque époque le modèle apprend plus d'informations. Si l'accuracy est diminuée, alors on aura besoin de plus d'information pour faire apprendre notre modèle et par conséquent on doit augmenter le nombre d'époque et vice versa. De même, l'erreur (LOSS) d'apprentissage et de la validation diminue avec le nombre d'époque, voir la figure 3.5.



Figure 3.4 : Courbe d'accuracy de l'entraînement et de la validation



Figure 3.5: Courbe de perte de l'entraînement et de la validation

3.4.4 Evaluation des performances

La matrice de confusion permet d'évaluer la performance de notre modèle, puisqu'elle reflète les métriques du Vrai positif, Vrai négatif, Faux positif et Faux négatif. La figure 3.6 illustre de près la position de ces métriques pour chaque classe.

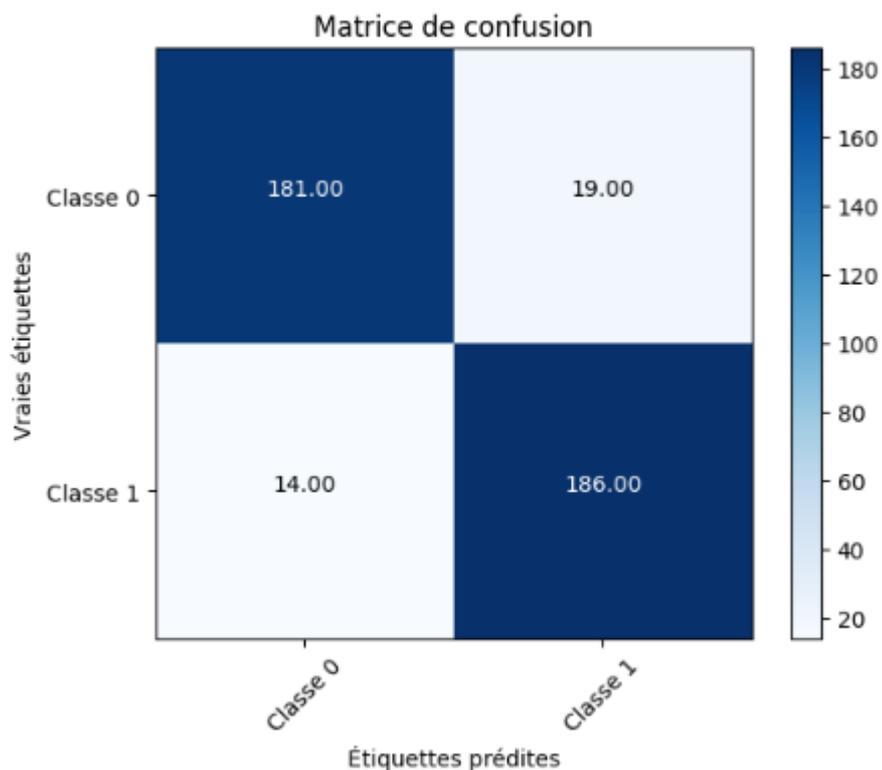


Figure 3.6: Matrice de confusion de notre modèle.

L'indicateur synthétique associé à la courbe ROC est la surface située sous la courbe, c'est l'AUC (Area Under the Curve). Un modèle de classification est performant si l'AUC est proche de 1. La figure 3.7 illustre la courbe ROC de notre système.

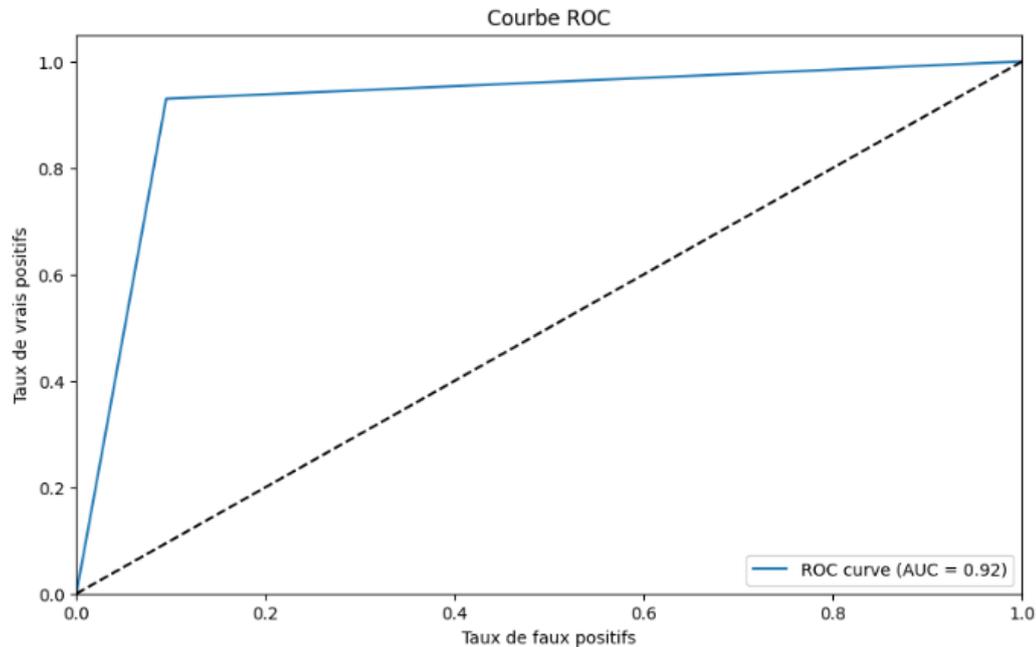


Figure 3.7: Courbe ROC pour l'évaluation de performance de notre système

Nous calculons et résumons dans un tableau un ensemble de mesures de performance pour notre système de contrôle par vérification de la parenté (Tableau 3-1).

Tableau 3-1 : Evaluation des performances du modèle

Métriques	Accuracy	Sensibilité	Précision	F-mesure
Valeurs	0.9175	0.93	0.91	0.92

3.4.5 Interface de contrôle d'accès par vérification de la parenté

Pour l'exécution de notre système de contrôle d'accès nous réalisons une interface graphique afin d'effectuer automatiquement la vérification de parenté. Une fois le modèle entraîné, nous effectuons une prédiction directement pour une paire d'image. La figure 3.8 nous donne un aperçu de l'interface graphique.

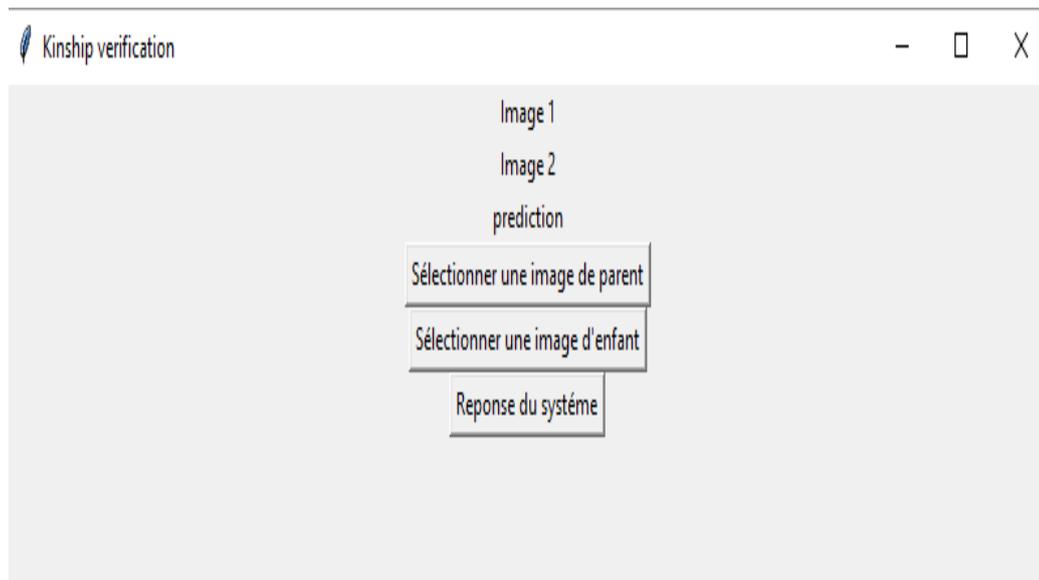


Figure 3.8 : Aperçu de l'interface

Cette interface est composée de 3 boutons :

- Le premier bouton nous permet de sélectionner l'image du parent,
- Le deuxième bouton nous permet de sélectionner l'image de l'enfant,
- Le troisième bouton exécute toute les étapes du système de contrôle par vérification d'image de visage citer plus haut nous donne en sortie la classe prédite et les réponses attendues : -s'il existe ou pas un lien de parenté ; -si l'accès est autorisé ou refusé.

Dans la figure 3.9 nous effectuons un test en utilisant une paire d'image (l'une de l'enfant et l'autre de parent) ayant une relation une vraie relation de parenté. La réponse du système est 1 pour la classe prédite dont il affirme qu'il y'a un lien de parenté et que l'accès est alors autorisé.

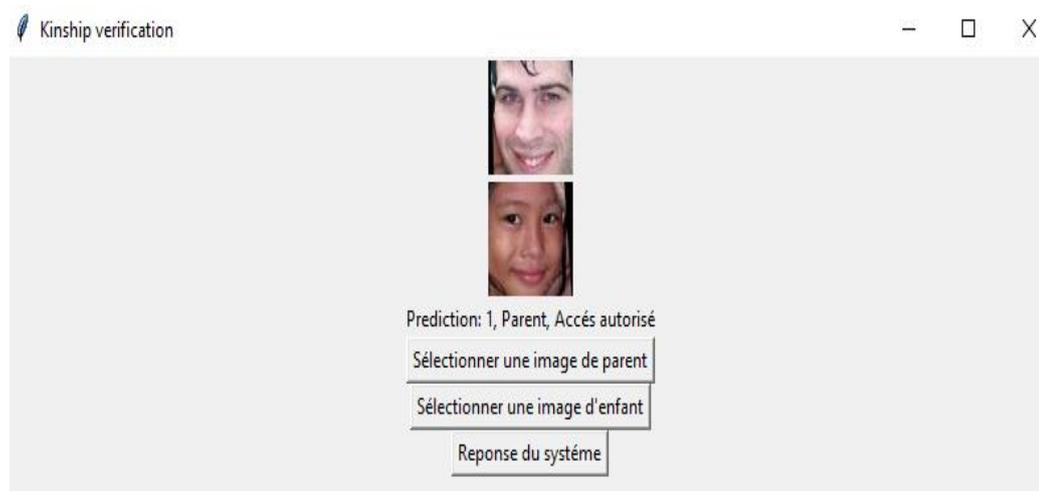


Figure 3.9: Exemple utilisant une paire d'image de relation vrai

Dans la figure 3.9, nous effectuons un test en utilisant une paire d'images (une de l'enfant et l'autre du parent) qui ont une véritable relation de parenté. La réponse du système est 1 pour la classe prédite, ce qui indique qu'il affirme l'existence d'un lien de parenté et autorise l'accès en conséquence.



Figure 3.10 : Exemple utilisant une paire d'image de relation inexistante

3.4.6 Discussion

Notre méthode a fourni un résultat assez satisfaisant soit un taux de bonne reconnaissance de 91.75%. Un résultat jugé meilleur que plusieurs travaux cités dans la section des travaux connexes pour la vérification de la parenté par apprentissage profond, tels que le travail de Lu et al. [32] en 2017, qui ont obtenu un taux de réussite de 84,3% avec le modèle DDMML, ou encore le travail de Zhang et al. [33] en 2021, avec le modèle AdvKin qui ont atteint une précision de 88% sur la base de données KinFaceW-II. À cet égard, nous considérons notre approche satisfaisante.

3.5 Conclusion

Dans ce chapitre, nous avons détaillé les points suivants : l'implémentation de notre méthode, l'interface graphique de notre système, les tests et les résultats de notre apprentissage. Au début, nous avons présenté les logiciels et les langages de programmation utilisés. Par la suite, nous avons présenté les différentes étapes nécessaires pour l'implémentation de la méthode proposée. Enfin, nous avons utilisé la précision et la courbe ROC pour évaluer les performances de la méthode.

Conclusions et travaux futures

4.1 Conclusions

Ce mémoire explore le thème du contrôle d'accès par vérification de la parenté à partir d'images en mettant en œuvre l'apprentissage profond des caractéristiques à l'aide des réseaux de neurones convolutifs. L'objectif principal est de concevoir un système novateur et fiable permettant d'authentifier le lien de parenté entre deux individus en se basant sur les caractéristiques communes entre les membres d'une même famille.

Notre système comprend quatre étapes importantes : la détection et le traitement des images de visage, l'extraction des caractéristiques et la classification par les CNN pour obtenir un résultat (parent ou non parent), et enfin, l'autorisation d'accès. Le CNN proposé a été entraîné et utilisé pour extraire les caractéristiques discriminantes des visages dans chaque image, puis une fonction de classification softmax a été utilisée pour distinguer les similarités et les différences entre les membres d'une même famille. Les résultats expérimentaux obtenus démontrent un taux de bonne reconnaissance prometteur de 91.75% pour la vérification de la parenté. Cette précision témoigne de l'efficacité de l'apprentissage profond des caractéristiques et de l'utilisation des CNN dans le contexte spécifique de la vérification de la parenté à partir d'images faciales. Ces résultats positifs ouvrent de nouvelles perspectives pour les applications de contrôle d'accès. La vérification de la parenté peut être utilisée dans divers domaines tels que la sécurité résidentielle, l'accès à des zones restreintes ou sensibles ainsi que dans des scénarios d'identification en environnement familial. Les familles pourront bénéficier d'une sécurité accrue et d'une plus grande commodité en utilisant des systèmes de contrôle d'accès basés sur la vérification de la parenté.

Il est important de noter que ce mémoire n'explorait qu'une approche spécifique pour le contrôle d'accès par vérification de la parenté et qu'il existe encore de nombreuses possibilités de recherche et d'amélioration.

4.2 Travaux futurs

Des travaux futurs pourraient inclure :

- L'élargissement de la base de données pour inclure davantage de familles et de diversité ethnique.
- L'exploration d'autres architectures de réseaux de neurones convolutifs.
- L'intégration de techniques de post-traitement pour améliorer davantage la précision et la robustesse du système.

Bibliographie

- [1] L. Li, X. Feng, X. Wu, Z. Xia and A. Hadid, "Kinship verification from faces via similarity metric based convolutional neural network," in *International conference on analysis and recognition images*, 2016.
- [2] "Wikipedia/parenté," [Online]. Available: <https://fr.m.wikipedia.org/wiki/Parent%C3%A9>. [Accessed 20 03 2023].
- [3] M. Mokri, «Classification des images avec les réseaux de neurones convolutionnels», Mémoire de fin d'étude Master, Spécialité Informatique, Université Abou Bakr Belkaid Tlemcen, 2015.
- [4] W. Xiaoting, F. Xioyi, C. Xiaochun, X. Xin, H. Dewen, B. Miguel and L. Li, "Facial Kinship verification: comprehensive review and outlook," *International journal of computer vision*, pp. 130 :1494-1525, 2022.
- [5] R. Fang, K. Tang, N. Snavely and T. Chen, "Towards computational models of kinship verification," in *International conference IEEE on image processing*, 2010.
- [6] A. Mohammed, Z. Siti, H. Mohd, M. Dzulkifli, H. A. Mohammed and A. Aida, "Automated kinship verification and identification through human facial images: a survey," *Sprinter science+business media new york 2015*, 2017.
- [7] L. Fan, L. Zewen, Y. Wenjie and X. Feng, "Age-Invariant Adversarial Feature Learning For Kinship verification," *Mathematics*, vol. 10, no. 3, p. 480, 2022.
- [8] A. Alexandra, F. Charlotte and R. Michel, "Differential facial resemblance of young children to their parents: who do childrens look like more?," *Evolution and human behavior*, pp. 28(2),135-144, 2007.
- [9] M. Dal and L. Maloney, "Lateralization of kin recognition signals in the human face," *Journal of vision*, pp. 10(8), 9–9, 2010.
- [10] M. Dal and L. Maloney, "Where are kin recognition signals in the human face?," *Journal of vision*, pp. 6(12), 2–2., 2006.
- [11] L. Maloney and M. Dal, "Kin recognition and the perceived facial similarity of children," *Journal of Vision*, pp. 6(10), 4–4, 2006.
- [12] D. Eran and K. Yosi, "A unified approach to kinship verification," *Transactions IEEE on pattern analysis and machine intelligence*, vol. 43, no. 8, pp. 2851-2857, 2020.
- [13] W. Li, Y. Zhang, J. Lu, J. Feng and J. Zhou, "Graphe based kinship reasoning network," in *International conference IEEE on multimédia and exposition (ICME)*, 2020.
- [14] H. Yan and S. Wang, "Learning part-aware attention networks for kinship verification," *Pattern recognition letters*, pp. 128, 169–175, 2019.
- [15] S. Wang and H. Yan, "Discriminant sampling via deep reinforcement learning for kinship verification," *Pattern recognition letters*, pp. 138, 38–43, 2020.
- [16] I. Ertugrul and H. Dibeklioglu, "What will your future child like? Modeling and synthesis of hereditary patterns of facial dynamics," in *12e international conference IEEE on automatic face and gesture recognition*, 2017.
- [17] R. Fang, A. Gallagher, T. Chen and A. Loui, "Kinship classification by modeling facial feature heredity," in *International conference IEEE on image processing*, 2013.

- [18] Q. Xiaoqian, T. Xiaoyang and C. Songkan, "Tri-subjects kinship verification: Understanding the core of a family," in *IEEE Transactions on Multi media*, 2015.
- [19] M. Shao, S. Xia and Y. Fu, "Genealogical face recognition based on UB KinFace database," in *Ateliers CVPR*, 2011, p. 60–65.
- [20] W. Xioting, G. Eric, H. K. Tomi, F. Xioyi and H. Abdenour, "Audio-visual kinship verification in the wild," in *internationale conference on biometrics (ICB)*, 2019.
- [21] X. Chao, X. Siyu, Z. Yuan, Z. Le and S. Ming, "Graph based family relationship recognition from a single image," in *International conference on artificial intelligence*, 2018.
- [22] L. Miguel Bordallo, B. Elhocine and H. Abdenour, "Comments on the “kinship face in the wild” data sets," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016.
- [23] A. Moujahid and F. Dornaika, "A pyramid multi-level face descriptor : application to kinship verification," *Multimedia Tools and Applications*, vol. 78, pp. 9335-9354, 2018.
- [24] G. Toshan and M. Aarti, "Eccentricity based kinship verification from facial images in the wild," *Pattern Analysis and Applications*, pp. 1-26, 2020.
- [25] L. Jiwen, Z. Xiuzhuang, T. Yap-Pen, S. Yuanyuan and Z. Jie, "Neighborhood repulsed metric learning for kinship verification.," *EEE Transactions on Pattern Analysis and Machine Intelligence*, p. 36(2) :331–345, 2014.
- [26] F. Ruogu, D. Kevin, S. Noah and C. Tsuhan, "Cornell university," [Online]. Available: <https://chenlab.ece.cornell.edu/projects/KinshipVerification>. [Accessed 6 4 2023].
- [27] "Northeastern University," [Online]. Available: <https://www1.ece.neu.edu/-yunfu/research/Kinface.htm>. [Accessed 6 6 2023].
- [28] X. Zhou, K. Jin, M. Xu and G. Guo, "Learning deep compact similarity metric for kinship verification from face images," *Information Fusion*, p. 48 :84–94, 2019.
- [29] M. Bessaoudi, A. Ouamane, M. Belahcene, A. Chouchane, E. Boutellaa and S. Bourennane, "Multilinear principal component analysis for face recognition with fewer features," *Neurocomputing*, p. 329(10) :267 – 278, 2019.
- [30] F. Dornaika, I. Arganda-Carreras and S. O, "Transfer learning and feature fusion for kinship verification," *Neural Computing and Applications*, vol. 32, pp. 7139-7151, 2020.
- [31] J. Lu, J. Hu, X. Zhou, J. Zhou, M. Castrillón-Santana, J. Lorenzo Navarro, L. Kou, Y. Shang, A. Bottino and T. Vieira, "Kinship verification in the wild: The first kinship verification competition," in *International conference IEEE on biométrie*, 2014.
- [32] L. Jiwen, H. Junlin and T. Yap-Peng, "Discriminative deep metric learning for face and kinship verification," *IEEE Transactions on Image Processing*, p. 26(9) :4269–4282, 2017.
- [33] Z. Lei, D. Qingyan, Z. David, J. Wei and W. Xizhao, "Advkin : Adversarial convolutional network for kinship verification," *IEEE Transactions on Cybernetics*, p. 51(12) :5883–5896, 2021.
- [34] "2n," [Online]. Available: https://www.2n.com/fr_FR/blog/l-histoire-du-controle-d-acces-porte. [Accessed 26 05 2023].
- [35] "Dormakaba," [Online]. Available: <https://blog.dormakaba.com/fr/les-5-differents-types-de-controle-dacces/>. [Accessed 25 04 2023].
- [36] "Wikipedia," [Online]. Available: https://www.fr.m.wikipedia.org/wiki/Courbe_ROC. [Accessed 6 06 2023].

- [37] "Wikipedia/rcn," [Online]. Available: https://fr.m.wikipedia.org/wiki/R%C3%A9seau_neuronal_convolutif. [Accessed 02 05 2023].
- [38] "Open Classrooms/classez," [Online]. Available: <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn>. [Accessed 16 05 2023].
- [39] "Open Classrooms/rcn," [Online]. Available: <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quun-reseau-de-neurone-convolutif-ou-cnn>. [Accessed 20 05 2023].
- [40] "Open Classrooms/couche," 22 04 2023. [Online]. Available: <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn>.
- [41] "Insee," [Online]. Available: http://www.jms-insee.fr/2018/S08_3_ACTE_TARAYOUN_JMS2018.pdf. [Accessed 03 06 2023].
- [42] "Kobia," [Online]. Available: <https://kobia.fr/classification-metrics-accuracy>. [Accessed 05 06 2023].
- [43] "microsoft," [Online]. Available: <https://learn.microsoft.com/fr-fr/azure/cognitive-services/language-service/custom-text-classification/concepts/evaluation-metrics>. [Accessed 5 06 2023].
- [44] "Open Classrooms/aprenez," [Online]. Available: <https://openclassrooms.com/fr/courses/7168871-apprenez-les-bases-du-langage-python>. [Accessed 26 05 2023].
- [45] "Wikipedia," [Online]. Available: <https://www.fr.m.wikipedia/wiki/tensorflow>. [Accessed 20 05 2023].
- [46] "Keras," [Online]. Available: <https://keras.io>. [Accessed 20 05 2023].
- [47] "Wikipedia/Pycharm," [Online]. Available: <https://fr.m.wikipedia.org/wiki/Pycharm>. [Accessed 26 05 2023].
- [48] "KinFaceW," 15 03 2023. [Online]. Available: <https://www.kinfacew.com>.