

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

SCIENTIFIQUE

Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj

Institut d'Electronique et des Télécommunications

Mémoire

Présenté pour obtenir

LE DIPLOME DE MASTER

FILIERE : ELECTRONIQUE

Spécialité : Electroniques des Systèmes Embarqués

Intitulé

**Reconnaissance faciale du genre humain basée
sur les modèles d'apprentissage automatique**

Présenté par:

- Fedjiri Farida
- Noui Lina

Encadré par:

Dr. Hacine Gharbi Abdenour

Composition du jury:

Président: Pr. Talbi Mouhamed Lamine

Examineur: Dr. Adoui Ibtissem

Encadreur: Dr. Hacine Gharbi Abdenour

Année Universitaire: 2025-2026

REMERCIEMENTS

Ce travail marque l'aboutissement de plusieurs années d'études, de persévérance et d'efforts. Il représente la conclusion d'un parcours riche en apprentissages, en défis et en expériences enrichissantes. À cette occasion, nous tenons à exprimer notre profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire.

Avant tout, nous remercions **Allah**, le Tout-Puissant, de nous avoir accordé la santé, la force, la patience et la détermination nécessaires pour mener à bien ce travail. Nous Lui sommes reconnaissants pour toutes les bénédictions qu'Il nous a accordées tout au long de notre parcours. Nous adressons nos plus sincères remerciements à nos très chers parents, qui ont toujours cru en nous et nous ont soutenus sans relâche. Leur amour, leurs sacrifices, leurs encouragements permanents, leur confiance et leurs prières ont été une source inépuisable de motivation. Aucun mot ne saurait exprimer pleinement notre reconnaissance envers eux. Que Dieu les protège et les récompense pour tout ce qu'ils ont fait pour nous. Nous tenons à exprimer notre profonde gratitude à notre encadreur,

M. Hacine Gharbi Abdenour, pour son accompagnement, sa disponibilité, sa patience et ses précieux conseils. Ses orientations pertinentes, ses remarques constructives ainsi que son soutien constant ont largement contribué à l'élaboration et à l'aboutissement de ce mémoire. Nous adressons également nos sincères remerciements aux membres du jury qui nous font l'honneur d'examiner ce travail. Nous leur sommes reconnaissants pour le temps qu'ils consacrent à son évaluation ainsi que pour leurs remarques et suggestions qui contribueront à son amélioration. Nos remerciements s'étendent à l'ensemble des enseignants du **Département d'Électronique** qui ont assuré notre formation tout au long de notre cursus universitaire. Grâce à leur dévouement, leur compétence et la qualité de leur

enseignement, nous avons pu acquérir les connaissances scientifiques et techniques nécessaires à la réalisation de ce projet.

Nous adressons nos sincères remerciements à toutes les personnes qui nous ont soutenus, conseillés et encouragés tout au long de ce parcours. Qu'elles trouvent ici l'expression de notre profonde gratitude et de nos remerciements les plus chaleureux.

Dédicace

Je dédie ce travail, fruit de plusieurs années d'efforts, de patience et de persévérance,

À mes très chers parents,

Aucune dédicace, aucun mot, aussi sincère soit-il, ne saurait exprimer l'immense gratitude, l'amour et le respect que je vous porte. Merci pour vos sacrifices, votre soutien inconditionnel, vos encouragements permanents et vos prières qui m'ont accompagnée à chaque étape de mon parcours. Si j'ai pu atteindre ce jour, c'est grâce à vous. Que Dieu vous protège, vous accorde une longue vie et vous récompense pour tout ce que vous avez fait pour moi.

À ma famille, Mon frère et mes sœurs

Pour son affection, sa confiance et son soutien dans les moments les plus difficiles comme dans les plus heureux.

À mes amies et à toutes les personnes qui ont partagé avec moi ce parcours universitaire, pour leur présence, leur aide et les souvenirs inoubliables que nous avons construits ensemble.

À ma chère amie Lina, ma compagne de route dans ce parcours, mon binôme avec qui j'ai partagé tous les moments de fatigue avant la joie, des nuits blanches, du stress, mais aussi des rires même dans les moments les plus difficiles... Merci d'avoir été mon soutien, merci pour ta patience, ta collaboration, et chaque instant où nous avons travaillé main dans la main pour arriver à ce résultat. Ce travail n'est pas seulement un mémoire, c'est un beau souvenir qui nous unit et le reflet de nos efforts communs. Que Dieu préserve notre amitié et nous accorde la réussite pour la suite.

Enfin, à toute personne qui a cru en moi, m'a encouragée et m'a donné la force d'avancer lorsque le chemin paraissait difficile.

Je dédie humblement ce travail à tous ceux qui occupent une place précieuse dans mon cœur.

Fedjiri Farida

Dédicace

Je dédie ce modeste travail à tous ceux qui, par leur amour, leur soutien et leurs prières, ont contribué à faire de ce rêve une réalité :

À ma chère mère, Source de bonheur et de tendresse, toi qui as toujours éclairé mon chemin vers la réussite par ton amour, tes conseils précieux et ton soutien constant. Tu as été pour moi une source de force et de courage dans les moments les plus difficiles. Quels que soient mes mots, ils ne suffiront jamais à exprimer toute ma gratitude pour tout ce que tu m'as donné depuis mon enfance. Merci pour ton affection, tes sacrifices et tes prières. Que Dieu te protège, et que ta bénédiction m'accompagne toujours.

A mon très cher papa, Symbole de sagesse, de patience et de dévouement, toi qui as toujours été à mes côtés par ton soutien, tes encouragements et tes précieux conseils. Tu m'as guidée avec confiance et m'as aidée à avancer tout au long de mon parcours. Je te remercie sincèrement pour tout ce que tu as fait pour moi. Que Dieu te protège, t'accorde santé, bonheur et longue vie.

À mes très chers frères et à ma sœur, Vous êtes les sourires qui illuminent mes journées et les épaules solides qui m'ont soutenue dans les moments difficiles. Votre présence a toujours été pour moi une source de réconfort et de joie.

À toute ma famille, sans exception, chacun et chacune par son nom, je vous porte tous dans mon cœur. Je vous aime profondément.

À mes précieuses amies, Pour votre amitié sincère, votre soutien moral et tous les beaux souvenirs partagés. Vous avez rendu ces années plus belles et inoubliables. Que notre amitié reste toujours forte. Je vous souhaite beaucoup de bonheur et de réussite dans votre vie. Je vous aime énormément.

À mon binôme Farida, Merci pour ton amitié sincère, ton soutien et ta présence dans les moments de doute comme dans les instants de joie. Avec toi, j'ai partagé les rires, les défis et les réussites qui ont marqué ce parcours universitaire. Ton implication et ta générosité ont rendu ce travail plus riche et plus agréable. Que Dieu t'accorde bonheur, santé et réussite.

Enfin, à toute personne qui nourrit à mon égard un sentiment d'amour, d'amitié ou de respect, je vous dis tout simplement : **MERCI.**

Noui Lina

Résumé

La reconnaissance du genre facial est l'une des tâches fondamentales de la vision par ordinateur, avec des applications variées telles que l'interaction homme-machine, la vidéosurveillance et le marketing ciblé. Notre travail consiste à implémenter un système performant de reconnaissance faciale du genre (RFG) basé sur le descripteur HOG (Histogram of Oriented Gradients), combiné à trois algorithmes d'apprentissage automatique : SVM (Support Vector Machine), LDA (Linear Discriminant Analysis) et KNN (K-Nearest Neighbor). Les performances du système ont été évaluées sur une sous base de données extraite de la base de données FERET, composée de 836 images faciales des deux genres (masculin, féminin). Les résultats ont montré que le modèle SVM avec noyau RBF atteint le meilleur taux de reconnaissance de 94,50 % avec une taille d'image de 256×256 pixels et une cellule HOG de 8×8, suivi du LDA avec 90,19 % et du KNN avec 84,69 %.

En parallèle, une étude comparative a été menée avec le descripteur LBP, qui s'est révélé efficace pour représenter la texture faciale, mais dont les performances restent inférieures à celles obtenues avec HOG. Cette comparaison confirme la pertinence du choix du descripteur HOG associé au classificateur SVM pour notre système de reconnaissance faciale.

Mots clés : Reconnaissance faciale du genre, Descripteur HOG, apprentissage automatique, classification, SVM, KNN, LDA.

Abstract

Facial gender recognition is one of the fundamental tasks of computer vision, with various applications such as human-machine interaction, video surveillance, and targeted marketing. Our work involves implementing a high-performance gender recognition facial system (GRFS) based on the HOG (Histogram of Oriented Gradients) descriptor, combined with three algorithms of machine learning: SVM (Support Vector Machine), LDA (Linear Discriminant Analysis), and KNN (K-Nearest Neighbor). The system's performance was evaluated on the FERET database, which consists of 836 facial images of both genders (male, female). The results showed that the SVM model with RBF kernel achieved the best recognition rate of 94.50% with an image size of 256×256 pixels and an HOG cell of 8×8, followed by LDA with 90.19% and KNN with 84.69%.

In parallel, a comparative study was conducted with the LBP descriptor, which proved effective in representing facial texture, but whose performance remains inferior to that

obtained with HOG. This comparison confirms the relevance of choosing the HOG descriptor associated with SVM classifier for our facial gender recognition system.

Keywords: Gender facial recognition, HOG descriptor, machine learning, classification, SVM, KNN, LDA.

ملخص

التعرف على الجنس من الوجه هو أحد المهام الأساسية في رؤية الكمبيوتر، مع تطبيقات متنوعة مثل التفاعل بين الإنسان والآلة، والمراقبة بالفيديو، والتسويق المستهدف. عملنا يتضمن تنفيذ نظام فعال للتعرف على الجنس من الوجه (RFG) يعتمد على موصوف (Histogram of Oriented Gradients) HOG، مدمجًا مع ثلاث خوارزميات SVM: (Support Vector Machine)، (Linear Discriminant Analysis) LDA و (K-Nearest Neighbor) KNN. تم تقييم أداء النظام على مجموعة فرعية من البيانات المستخرجة من قاعدة بيانات FERET، والتي تتكون من 836 صورة وجهية من كلا الجنسين (ذكور وإناث). أظهرت النتائج أن المصنف SVM مع نواة RBF يحقق أفضل معدل تعرف بنسبة 94.50% مع حجم صورة 256×256 بكسل وخلايا HOG بحجم 8×8، يليه LDA بنسبة 90.19% و KNN بنسبة 84.69%. في الوقت نفسه، تم إجراء دراسة مقارنة مع موصوف LBP، الذي أثبت فعاليته في تمثيل نسيج الوجه، لكن أدائه لا يزال أقل من الأداء الذي تم الحصول عليه باستخدام HOG. تؤكد هذه المقارنة على ملائمة اختيار موصوف HOG المرتبط بمصنف SVM لنظام التعرف على الوجه الخاص بنا.

الكلمات المفتاحية : التعرف على الوجه حسب الجنس، موصوف HOG، التعلم الآلي، التصنيف، SVM، KNN،

LDA.

Table des matières

Introduction générale.....	1
-----------------------------------	----------

Chapitre I : Généralités sur la reconnaissance faciale du genre

I.1 Introduction	5
I.2 Définition du genre.....	5
I.3 Reconnaissance faciale et reconnaissance du genre.....	5
I.4 Classification du genre.....	6
I.5 Applications de la reconnaissance du genre.	7
I.6 Modalités de reconnaissance du genre.....	7
I.7 Système de reconnaissance faciale du genre.....	8
I.7.1 Phase d'apprentissage.....	9
I.7.1.1Détectionduvisage.....	10
I.7.1.2 L'extraction de paramètres	10
I.7.1.3La classification.....	10
I.7.2 Phase de test.....	10
I.8 Méthodes d'extraction des caractéristiques	11
I.9 Méthodes de classification.....	11
I.10 Bases de données utilisées	12
I.10.1Base de données FERET	12
I.11 mesures de performances	13
I.12 Etat de l'art	13
I.13 Conclusion.....	14

Chapitre II : Conception d'un Système de reconnaissance Faciale du Genre basé sur les algorithmes de machine Learning

II.1Introduction.....	16
II.2. Système RFG proposé basé sur les algorithmes de machine Learning.....	16
II.3Apprentissage automatique (Machine Learning)	17
II.3.1 Définition du Machine Learning	17
II.3.2 Types d'apprentissage	17
II.3.2.1 Apprentissage supervisé.....	17

II.3.2.2 Apprentissage non supervisé	18
II.4 Base de données utilisée.....	18
II.5 Description des étapes du fonctionnement du système RFG	19
II.5.1. Préparation des données d'apprentissage et de test	20
II.5.2 Prétraitement des images faciales	20
II.5.3 Extraction des caractéristiques.....	21
II.5.3.1 Histogramme des gradients orientés (HOG)	21
II.5.3.2 Local Binary Patterns (LBP)	24
II.5.4 Classification	25
II.5.4.1 K plus proches voisins (KNN).....	26
II.5.4.2 Machine à vecteurs de support (SVM).....	28
II.5.4.3 L'analyse discriminante linéaire (LDA)	29
II.5.5 Evaluation des performances.....	29
II.6 Conclusion	30

Chapitre III : Evaluation et résultats

III.1 Introduction	32
III.2 Protocole d'évaluation utilisé	33
III.3 Expérimentations et Résultats	33
III.3.1 Environnement de travail	33
III.3.1.1 Environnement matériel	33
III.3.1.2 Environnement logiciel	33
III.3.2 Expériences et résultats	34
Expérience1 : Meilleure configuration du classificateur SVM	34
Expérience2 : Optimisation du classificateur KNN	37
Expérience3 : Évaluation du classificateur LDA.....	38
Expérience 4 : Analyse des performances temporelles	41
Expérience 5 : Évaluation des performances du descripteur LBP associé au classificateur KN...41	
III .4 Discussion	42
III.5 Étude comparative	44
III.6 Conclusion	45
Conclusion générale.....	46

Liste des figures

Figure I.1 : Détection de visage.....	6
Figure I.2 : Differentes-modalites pour les systèmes RFG.....	8
Figure I.3 : Architecture d'un système de reconnaissance faciale du genre.....	9
Figure I.4 : Base de données.....	9
Figure I.5 : Les étapes d'un système RFG.....	11
Figure II.1 : Schéma de fonctionnement du système RFG proposé, basé sur les algorithmes de machine Learning.....	17
Figure II.2 : Exemples d'images faciales de la base de données FERET.....	18
Figure II.3 : Diagramme fonctionnel du système RFG implémenté.....	20
Figure II.4 : Etape de prétraitement.....	21
Figure II.5 : Histogramme de gradients orientés.....	22
Figure II.6 : Local Binary Patterns.....	25
Figure II.7 : Illustration du principe K-Nearest Neighbors (KNN).....	27
Figure II.8 : Machine à vecteurs de support.....	29

Liste des tableaux

Tableau I.1 : Etat de l'art sur la reconnaissance faciale du genre.....	14
Tableau II.1 : Répartition des données d'apprentissage et de test.....	19
Tableau III.1 : Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau linéaire pour différentes tailles d'images et tailles de cellules HOG.....	35
Tableau III.2: Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau RBF pour différentes tailles d'images et tailles de cellules HOG.....	35
Tableau III.3 : Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau Polynomial pour différentes tailles d'images et tailles de cellules HOG.....	36
Tableau III.4: Comparaison des performances des noyaux SVM avec la configuration optimale du descripteur HOG.....	36
Tableau III.5 : Influence de la taille des images et de la taille des cellules HOG sur les performances du KNN -----	37
Tableau III.6 : Influence de la métrique de distance sur les performances du classificateur KNN.....	38
Tableau III.7 : Influence de la taille des images et des cellules HOG sur les performances du classificateur LDA.....	39
Tableau III.8 : Résultats du classificateur Diaglinear avec la même configuration HOG.....	39
Tableau III.9 : Influence de la taille des images et et de la taille des cellules HOG sur les performances du classificateur PseudoLinear.....	40
Tableau III.10 : Résultats des différents noyaux du LDA.....	40
Tableau III.11 : Comparaison des performances temporelles des classificateurs.....	41
Tableau III.12 : taux de reconnaissance (%) du classificateur KNN avec le descripteur LBP.....	42
Tableau III.13 : Comparaison des performances des classificateurs.....	42
Tableau III.14 : Etude comparative avec [1].....	44

Abréviations

RFG : Reconnaissance Faciale du Genre.

FERET: Facial Evaluation Recognition Technology.

LBP: Local Binary Patterns.

HOG: Histogram of Oriented Gradients

K-NN: k-Nearest Neighbor.

SVM: Support Vector Machine.

GMM: Gaussian Mixture Model.

LDA: Linear Discriminant Analysis.

CNN: Convolutional Neural Network.

BSIF: Binarized Statistical Image Features.

H : Homme, Masculin.

F : Femme, Féminin.

ANN: Artificial Neural Network.

RBF: Radial Basis Function.

Introduction Générale

Le visage constitue une composante fondamentale du corps humain, car il permet de différencier chaque individu au sein de grandes populations [2].

Dans ce cadre, la reconnaissance faciale du genre (RFG) est considérée comme une tâche de classification visant à attribuer automatiquement à une image faciale l'une des deux classes : masculine 'H' ou féminine 'F'. Ce domaine a connu un intérêt croissant en raison de ses nombreuses applications dans divers secteurs tels que l'interaction homme-machine, l'analyse biométrique, le Marketing et la santé [2].

Parmi les différentes tâches liées à la reconnaissance faciale, la reconnaissance automatique du genre constitue un défi scientifique majeur puisqu'elle consiste à déterminer, à partir d'une simple image du visage, si une personne appartient au genre masculin ou féminin. Bien que cette opération puisse sembler triviale pour l'œil humain, elle requiert en réalité des techniques robustes capables de gérer des variations complexes telles que les changements d'éclairage, les orientations de la tête (pose), les différences morphologiques liées à l'âge ou encore les diverses expressions faciales. À ces facteurs s'ajoutent la couleur de la peau, l'origine ethnique ainsi que la présence d'accessoires tels que les lunettes, le voile et d'attributs faciaux tels que la barbe, qui influencent significativement les performances des systèmes de reconnaissance du genre et accentuent la complexité de la tâche. La conception d'un système de RFG robuste nécessite donc le recours à des méthodes efficaces d'extraction de caractéristiques et à des algorithmes de classification performants, afin de garantir une précision et une fiabilité optimales dans des conditions réelles et variées.

Dans un contexte technologique en constante évolution, où l'intelligence artificielle s'impose progressivement dans tous les secteurs de la vie quotidienne, la détection automatique du genre trouve des applications concrètes et variées. Dans le domaine de la sécurité et de la surveillance, elle permet d'enrichir les systèmes d'analyse comportementale et de contrôle d'accès. Dans le secteur du marketing et de la publicité intelligente, elle offre la possibilité de personnaliser les contenus en fonction du profil démographique des individus. Elle intervient également dans les interfaces homme-machine adaptatives, les systèmes de santé connectés, ainsi que dans les études statistiques et sociologiques nécessitant une classification automatique des populations.

C'est dans ce contexte que s'inscrit notre travail, qui propose un système de reconnaissance de genre fondé sur l'apprentissage automatique. Pour ce faire, nous avons utilisé la base de données FERET, largement reconnue dans le domaine, combinée à deux méthodes d'extraction de caractéristiques : HOG (Histogramme des gradients orientés), efficace pour capturer les contours et les textures discriminantes du visage, et LBP (Local Binary Patterns), particulièrement adapté à la description des micro-textures faciales. Trois classifieurs ont ensuite été mis en œuvre : la machine à vecteurs de support (SVM), l'algorithme des k-plus proches voisins (KNN) et l'analyse discriminante linéaire (LDA). La base de données utilisée contient des images faciales de femmes et d'hommes présentant différentes variabilités, notamment les conditions d'éclairage, les différences d'âge, les poses et la présence d'accessoires tels que les lunettes, ce qui permet d'évaluer la robustesse du système dans des contextes réalistes.

Le choix de ces algorithmes n'est pas arbitraire : ils représentent des approches complémentaires en termes de complexité, d'interprétabilité et de performance, ce qui permet une évaluation comparative rigoureuse et objective du système proposé.

La problématique centrale de ce travail peut être formulée ainsi : comment parvenir à reconnaître automatiquement le genre humain à partir d'images faciales en exploitant les techniques du Machine Learning ?

Afin de répondre à cette question, des réponses seront développées dans ce mémoire qui est structuré en trois chapitres. Le premier chapitre pose les bases en présentant des généralités sur la reconnaissance faciale du genre : définitions essentielles, caractéristiques du visage utilisé, principaux défis rencontrés ainsi en justifiant le choix de la base FERET. Le deuxième chapitre décrit en détail les étapes de fonctionnement et d'implémentation du système proposé, en expliquant l'extraction des descripteurs HOG et LBP, ainsi que le fonctionnement des algorithmes SVM, KNN et LDA. Le troisième chapitre, quant à lui, est consacré aux expériences effectuées et les résultats obtenus du système ainsi qu'à la discussion et l'interprétation des résultats.

Enfin, le mémoire se termine par une conclusion générale qui synthétise les apports de ce travail, tout en ouvrant des perspectives intéressantes pour des améliorations futures.

Chapitre I

Généralités sur la reconnaissance faciale du genre

I.1 Introduction

La reconnaissance faciale est une technologie basée sur l'analyse automatique des caractéristiques du visage afin d'extraire d'informations telles que l'identité, les émotions, l'âge et le genre d'une personne à partir d'images faciales ou de vidéos. Plus particulièrement, la Reconnaissance Faciale du Genre (RFG) a pour objectif de reconnaître la classe du genre (H : Masculin ou F : Féminin) d'une personne, en appliquant des outils du traitement d'images et des algorithmes d'apprentissage automatique sur son image faciale. Avec l'évolution rapide de l'intelligence artificielle et des systèmes de vision par ordinateur, la technologie RFG connaît un développement important et s'intègre progressivement dans de nombreux domaines tels que la sécurité, la surveillance, la biométrie, l'interaction homme-machine, le marketing et la santé. Cependant, malgré ses avantages, cette technologie soulève plusieurs préoccupations liées à la protection de la vie privée, à la sécurité des données et aux questions éthiques. Son déploiement dans les systèmes de surveillance et les environnements numériques suscite ainsi des débats importants sur ses impacts sociaux et juridiques.

I.2 Définition du genre

Le genre est une caractéristique descriptive permettant de classer un individu dans l'une des deux catégories principales, masculin ou féminin, et constitue dans le domaine de la vision par ordinateur et de la biométrie un attribut biométrique secondaire (soft biometric trait) qui peut être estimé automatiquement à partir des informations visuelles extraites du visage ; en effet, le genre représente une information démographique fondamentale pouvant être inférée à partir des caractéristiques faciales d'un individu, et la reconnaissance du genre consiste précisément à analyser les traits du visage afin de déterminer l'appartenance de la personne à l'une des deux classes, homme ou femme, une information qui joue un rôle important dans de nombreuses applications de reconnaissance et d'analyse faciale telles que la surveillance intelligente, le marketing ciblé et les systèmes d'identification automatique [3] [4].

I.3 Reconnaissance faciale et reconnaissance du genre

La reconnaissance faciale est une technologie biométrique clé de la vision par ordinateur et de l'intelligence artificielle, permettant d'identifier ou de vérifier l'identité d'un individu à partir des caractéristiques de son visage [3]. Dans ce cadre, la reconnaissance du genre en est une application spécifique : elle consiste à classer automatiquement un visage en catégories 'H' ou 'F' en se basant sur les informations visuelles extraites de l'image faciale [5]. Cette tâche, qui peut être binaire, s'appuie généralement sur l'analyse de la région du visage,

mais peut également intégrer des éléments contextuels comme les cheveux et le cou, fournissant des indices complémentaires [6]. Toutefois, les performances de ces systèmes sont affectées par des facteurs liés aux conditions d'acquisition (illumination, pose, qualité de l'image) ainsi que par des facteurs humains tels que l'âge, l'origine ethnique, les expressions faciales ou encore d'autres modalités biométriques (voix, etc.) [6]. La reconnaissance du genre repose donc souvent sur des modèles d'apprentissage automatique entraînés sur des ensembles de données labellisées, afin d'inférer l'identité de genre exprimée.




Figure I.1 : détection de visage

I.4 Classification du genre

La classification du genre a été initialement abordée dans le cadre des études psychophysiques, qui visent à comprendre le fonctionnement du système visuel humain ainsi qu'à identifier les caractéristiques faciales discriminantes permettant de différencier les individus de genre masculin et féminin. Les recherches ont montré que les variations entre les traits de masculinité et de féminité du visage constituent des indices pertinents pouvant être exploités pour améliorer les performances des systèmes de reconnaissance faciale dans plusieurs domaines, tels que la biométrie, l'interaction homme-machine, la surveillance et la vision par ordinateur. Toutefois, dans des environnements réels, cette tâche reste complexe en raison de nombreux facteurs de variabilité, notamment les conditions d'éclairage, les changements de pose, les expressions faciales, les occlusions, l'arrière-plan ainsi que le bruit. Par conséquent, le principal défi consiste à concevoir un système de classification du genre

basé sur le visage qui soit à la fois robuste, précis et capable d'assurer des performances en temps réel [7].

I.5 Applications de la reconnaissance du genre

Le développement des technologies de reconnaissance du genre a favorisé l'émergence de nombreuses applications dans divers domaines. Ces techniques de classification améliorent la perception et l'interaction des systèmes informatiques avec leur environnement, en renforçant leurs capacités d'analyse, de surveillance et d'adaptation. Elles sont également intégrées dans des systèmes intelligents, tels que les robots, afin d'ajuster leurs réponses en fonction du contexte et des utilisateurs [8].

Ces applications couvrent plusieurs secteurs. Dans le domaine de la sécurité et du contrôle d'accès, elles permettent le déverrouillage des appareils et la gestion des accès. Aux frontières, elles facilitent les contrôles à l'aide des passeports biométriques. Dans le secteur bancaire, elles assurent l'authentification des paiements en ligne. Elles sont aussi utilisées dans la lutte contre la criminalité pour identifier des suspects ou retrouver des personnes disparues. Par ailleurs, dans le commerce et le marketing, elles permettent d'analyser le comportement des clients afin d'optimiser les stratégies commerciales. On les retrouve également dans le domaine médical, pour l'identification des patients et l'aide au diagnostic, ainsi que dans l'analyse des émotions à travers les expressions faciales.

En résumé, ces technologies jouent un rôle essentiel dans le développement des systèmes intelligents et contribuent à améliorer l'efficacité, la sécurité et la qualité des interactions homme-machine [8] [9].

I.6 Modalités de reconnaissance du genre

Parmi les différentes modalités biométriques utilisées pour la classification du genre – telles que l'iris, la démarche ou la morphologie de la main – le visage demeure la plus exploitée. Cette prédominance s'explique par la richesse et la diversité des informations qu'il fournit : contour du visage, pilosité faciale (cheveux, barbe), texture de la peau, ainsi que des indices morphologiques subtils. Outre son rôle central dans l'interaction sociale, permettant l'identification des individus et la reconnaissance des émotions, le visage bénéficie d'une capacité humaine remarquable à mémoriser et distinguer des milliers de visages malgré les variations d'apparence.

Ces caractéristiques ont inspiré de nombreuses applications pratiques, notamment en sécurité (contrôle d'accès, vidéosurveillance), en authentification (systèmes biométriques) et

en identification criminelle. Toutefois, la modélisation automatique de la reconnaissance faciale reste un défi scientifique majeur, en raison de la variabilité des expressions, des conditions d'éclairage et des changements d'apparence liés à l'âge ou au contexte. C'est dans ce cadre que la classification du genre à partir d'images faciales s'impose comme un domaine de recherche actif, en constante évolution, mobilisant des approches classiques (HOG, SVM, KNN, GMM) et modernes (réseaux de neurones profonds) [10] [11] [12].




Figure 1.2 : Différentes-modalités pour les systèmes RFG.

I.7 Système de reconnaissance faciale du genre

Un système de reconnaissance faciale est une application informatique permettant d'identifier ou de vérifier automatiquement une personne à partir d'une image numérique ou d'une trame vidéo, notamment par comparaison des traits du visage sélectionnés avec une base de données. Par ailleurs, la reconnaissance faciale du genre constitue un moyen de communication non verbale utilisé par les humains pour faciliter l'interaction, notamment dans les domaines du marketing et de la médecine. Un tel système (RFG) vise à classer chaque image d'entrée selon une classe de genre facial à l'aide d'algorithmes d'analyse d'images et d'intelligence artificielle, et son fonctionnement repose sur trois étapes principales : la détection du visage, l'extraction des caractéristiques et la classification [1].




Figure I.3 : Architecture d'un système de reconnaissance faciale du genre.

La conception d'un système de reconnaissance faciale du genre (RFG) repose sur deux phases distinctes : une phase d'apprentissage et une phase de test. Ces deux étapes nécessitent respectivement une base de données d'apprentissage, permettant de modéliser les deux classes de genre, et une base de données de test, destinée à évaluer les performances du système.




Figure I.4 : Base de données.

I.7.1 Phase d'apprentissage :

Dans cette phase, le système apprend à distinguer les deux classes de genre : le genre féminin (F) et le genre masculin (M). Elle consiste à extraire et classifier les paramètres, puis à les stocker dans une base de données structurée. Cette base de données servira de référence lors

de la phase de reconnaissance, permettant au système de prendre une décision précise. En d'autres termes, cette phase représente la mémoire du système.

I.7.1.1 Détection du visage

Cette étape consiste à extraire l'image de l'utilisateur du monde extérieur dans un état statique à l'aide d'un appareil photo ou dynamique à l'aide d'une caméra. Après, l'image extraite sera digitalisée ce qui donne lieu à une représentation bidimensionnelle au visage, caractérisée par une matrice en niveaux de gris. L'image dans cette étape est dans un état brut ce qui engendre un risque de bruit qui peut dégrader les performances du système [13].

I.7.1.2 L'extraction de paramètres

En plus de la classification, l'étape de l'extraction des paramètres représente le cœur du système de reconnaissance, elle consiste à effectuer le traitement de l'image dans un autre espace de travail plus simple et qui assure une meilleure exploitation de données, et donc permettre l'utilisation, seulement, des informations utiles, discriminantes et non redondantes [13].

I.7.1.3 La classification

Cette étape consiste à modéliser les paramètres extraits d'un visage ou d'un ensemble de visages d'un individu en se basant sur leurs caractéristiques communes. Un modèle est un ensemble d'informations utiles, discriminantes et non redondantes qui caractérise un ou plusieurs individus ayant des similarités [13].

I.7.2 Phase de test :

Cette phase vise à évaluer les performances du système RFG en utilisant une base de données composée d'images faciales de test. Les étapes de détection et d'extraction des caractéristiques y sont appliquées de la même façon que lors de la phase d'apprentissage. En outre, une étape de classification est effectuée sur l'ensemble des caractéristiques extraites afin de déterminer le genre de l'image faciale analysée.




Figure I.5 : Les étapes d'un système RFG.

I.8 Méthodes d'extraction des caractéristiques

Dans le domaine de la reconnaissance faciale, la difficulté majeure réside dans la définition et l'extraction des caractéristiques les plus pertinentes d'un visage, c'est-à-dire celles qui rendent le mieux compte de l'information qu'il porte. Les caractéristiques locales présentent plusieurs avantages par rapport aux caractéristiques globales, ce qui explique que les systèmes récents privilégient les premières. Nous présentons ici deux types de descripteurs locaux parmi les plus performants : les histogrammes de gradients orientés (HOG) et les indices Local Binary Patterns (LBP). Chacun de ces types peut être exploité de différentes manières ; nous en décrivons ci-après le principe de base [14].

HOG (histogramme de gradients orientés) et LBP (motifs binaires locaux) sont deux techniques d'extraction de caractéristiques en traitement d'image, mais elles ciblent des aspects distincts de l'image : HOG se concentre sur le gradient et la direction des contours, tandis que LBP s'intéresse aux motifs de texture locaux. HOG calcule l'orientation du gradient dans l'image et construit un histogramme de ces directions sur de petites régions, ce qui le rend particulièrement efficace pour la détection d'objets comme les piétons, car il capture bien la structure des contours. En revanche, LBP examine la relation entre un pixel et ses voisins en codant ces motifs sous forme binaire, ce qui le rend très utile pour la classification de textures et la reconnaissance faciale. Ainsi, HOG est plus adapté aux tâches basées sur la forme, alors que LBP excelle dans l'analyse fondée sur la texture [14].

I.9 Méthodes de classification

La classification du genre constitue un domaine important de la vision par ordinateur et de l'intelligence artificielle. Elle consiste à attribuer une étiquette (homme ou femme) à un individu à partir de différentes sources d'information telles que les images, la voix ou les

données biométriques. Malgré sa simplicité apparente pour l'être humain, cette tâche demeure complexe pour les systèmes automatiques en raison de nombreux défis [15].

En reconnaissance faciale, avant l'avènement du Deep Learning, la classification reposait sur des méthodes classiques appliquées à des vecteurs de caractéristiques extraits (par exemple via PCA ou LDA). Parmi celles-ci, on trouve les k plus proches voisins (KNN), qui attribuent un visage test à la classe majoritaire parmi ses k voisins les plus proches dans la base de données ; les machines à vecteurs de support (SVM), qui cherchent une frontière de décision optimale pour séparer les individus ; ainsi que les classifieurs linéaires tels que LDA ou le perceptron, qui apprennent des règles simples sur les vecteurs après réduction de dimension.

I.10 Bases de données utilisées

Il existe plusieurs bases de données d'images faciales contenant des informations permettant d'évaluer les systèmes de reconnaissance de visages. Cependant, ces bases sont généralement conçues pour répondre aux besoins de quelques algorithmes spécifiques, chacune ayant été construite avec des conditions d'acquisition variées (changements d'éclairage, de pose, d'expressions faciales, de genre, d'âge, ainsi que le nombre de sessions par individu). Lors de l'analyse comparative d'un algorithme, il est recommandé d'utiliser un ensemble de données de test standard, ce qui permet de comparer directement les différents résultats obtenus par les chercheurs. Bien que de nombreuses bases de données soient actuellement disponibles, le choix de la base appropriée doit être effectué en fonction de la tâche à accomplir (vieillesse, expressions faciales, éclairage, etc.) [16].

Dans notre travail, nous avons utilisé une base de données extraite de la base de données FERET.

I.10.1 Base de données FERET :

La base de données FERET, développée dans le cadre d'un programme du NIST américain, a joué un rôle clé en fournissant une référence standardisée pour évaluer et comparer les algorithmes de reconnaissance faciale, à une époque où les chercheurs utilisaient des bases petites et hétérogènes. Constituée lors de 15 sessions entre 1993 et 1996 dans un environnement semi-contrôlé, elle rassemble des milliers d'images (14 126 au total pour 1 199 individus, avec des séances espacées de plus de deux ans pour certains). La première édition (2001) contient

14 051 images en niveaux de gris (256x384 pixels), tandis que la version récente (2003) propose 11 338 images couleur de haute qualité, corrigées d'erreurs antérieures, et inclut pour la plupart des individus des postures variées allant du profil gauche au profil droit avec rotation profonde de la tête [17].

I.11 mesures de performances

L'évaluation des performances d'un système de reconnaissance faciale du genre constitue une étape essentielle permettant de mesurer son efficacité et sa complexité. Parmi les indicateurs les plus utilisés figure le taux de classification (Accuracy), qui représente le pourcentage d'échantillons correctement classifiés parmi l'ensemble des données testées. Il constitue l'une des mesures les plus couramment employées pour évaluer les performances des systèmes de reconnaissance et de classification [3] [18].

Outre la précision, le temps de calcul représente un critère important puisqu'il reflète la rapidité d'exécution du système lors des étapes d'extraction des caractéristiques et de classification. Cette mesure est particulièrement importante dans les applications nécessitant un traitement en temps réel. Par ailleurs, l'espace mémoire correspond à la quantité de mémoire nécessaire au stockage des caractéristiques extraites ainsi que des paramètres du modèle de classification. L'étude conjointe de ces différents critères permet ainsi d'évaluer non seulement l'efficacité du système, mais également sa complexité et son aptitude à être déployé dans des environnements disposant de ressources limitées [3] [19].

I.12 Etat de l'art

Dans cette section, nous présentons un état de l'art des principaux travaux en reconnaissance faciale du genre, afin de mettre en évidence les différentes approches proposées en termes de descripteurs, de classificateurs et de bases de données.

Tableau I.1 : Etat de l'art sur la reconnaissance faciale du genre

Année	Descripteur de Caractéristiques	Classificateur	Base de données	Taux de reconnaissance
2004 [20]	ICA	LDA	FERET	99.3%
2011 [21]	LBP	SVM	LFW	94.8%
2016 [22]	HOG, LBP	SVM	FERET	92.6%
2019 [23]	HOG, SLBP	SVM	FERET	99.1%
2020 [1]	LBP	KNN	FERET	93.5%
2021 [24]	HOG, PCA, RILBP	SVM	BASE PUBLIQUE	99.6%
2023 [25]	HOG, PCA, SURF	SVM	UTK-FACE	97.43%

I.13 Conclusion

Ce chapitre a présenté les fondements théoriques et techniques de la reconnaissance faciale du genre, en définissant la reconnaissance faciale comme une technologie biométrique permettant d'identifier ou de vérifier une personne à partir de son visage, ainsi que son application spécifique à la classification du genre. Il a détaillé les principales étapes d'un système RFG, de la détection du visage à la classification, en passant par l'extraction des caractéristiques, tout en mettant en évidence le rôle important des descripteurs tels que HOG et LBP et des classifieurs classiques comme SVM et KNN. L'étude a également montré les limites des méthodes traditionnelles face aux conditions réelles de variation et a souligné l'importance des bases de données, notamment FERET, pour l'apprentissage et l'évaluation des modèles. Ainsi, ce chapitre constitue une base essentielle pour comprendre le fonctionnement global des systèmes de reconnaissance faciale du genre et ouvre la voie aux approches plus avancées.

Chapitre II

Conception d'un Système de reconnaissance Faciale du Genre basé sur les algorithmes de machine Learning

II.1 Introduction

Notre travail consiste à concevoir un système de reconnaissance faciale du genre (RFG) capable de classifier automatiquement des images faciales en deux classes, masculin (H) et féminin (F), en s'appuyant sur une approche globale dans laquelle chaque image est traitée dans son ensemble. L'objectif principal est de concevoir un système RFG performant en termes de précision et de complexité, en utilisant des algorithmes d'apprentissage automatique (machine Learning).

Dans ce chapitre, nous présentons l'architecture de notre système RFG proposé et ses étapes de fonctionnement en se basant sur les algorithmes de machine Learning. Nous présentons également les différentes étapes de traitement mises en œuvre, depuis la préparation des données jusqu'à l'évaluation des performances. Les expériences et les résultats d'implémentation seront détaillés dans le chapitre III.

II.2. Système RFG proposé basé sur les algorithmes de machine Learning

La conception d'un système RFG est un exemple de conception d'un système de reconnaissance de formes qui exige une phase d'apprentissage pour modéliser les deux classes du genre (H et F) en utilisant une base de données d'apprentissage, et une phase de test permettant de reconnaître des images faciales de test en utilisant des algorithmes de classification tels que : KNN (K-Nearest Neighbors), SVM (Support Vector Machine) et LDA (Linear Discriminant Analysis) pour évaluer les performances du système. Ces deux phases exigent chacune une étape d'extraction de paramètres permettant de convertir chaque image faciale en un vecteur de caractéristiques (paramètres) représentatives des classes H et F. Une étape de prétraitement d'image faciale est indispensable pour améliorer la qualité d'image brute d'entrée et faciliter la tâche d'extraction de paramètres. Ainsi, notre travail a pour objectif de concevoir un système performant en utilisant des algorithmes d'apprentissage automatique (machine Learning).

Dans notre travail, nous proposons d'appliquer les algorithmes de classification KNN, SVM et LDA combinés avec la méthode d'extraction HOG pour implémenter un système RFG précis, moins exigeant en temps de calcul et d'espace mémoire. Également, Nous proposons de comparer les performances du système proposé avec celles d'un système basé sur le descripteur LBP combiné avec le classificateur KNN.

Le schéma de fonctionnement du système RFG proposé est illustré sur la figure Fig.II.1 suivante :




Figure II.1 : Schéma de fonctionnement du système RFG proposé, basé sur les algorithmes de machine Learning

Dans les sections suivantes, nous présentons brièvement les fondements de l'apprentissage automatique, ainsi que les étapes d'implémentation du système RFG proposé.

II.3 Apprentissage automatique (Machine Learning)

II.3.1 Définition du Machine Learning

L'apprentissage automatique (Machine Learning) est un sous-domaine de l'intelligence artificielle qui repose sur le développement d'algorithmes capables d'apprendre à partir des données, sans être explicitement programmés. Contrairement à la programmation classique, il permet à un système d'extraire automatiquement des règles et des régularités à partir d'exemples, afin d'améliorer ses performances au fil du temps [26].

II.3.2 Types d'apprentissage

L'apprentissage automatique se divise en deux types d'algorithmes :

II.3.2.1 Apprentissage supervisé

L'apprentissage supervisé est une méthode d'entraînement basée sur des données étiquetées, où chaque exemple est associé à une sortie attendue. Le modèle apprend à établir une correspondance entre les entrées et les réponses cibles, puis prédit les résultats pour de nouvelles données. Cette approche est largement utilisée dans des domaines tels que la reconnaissance d'images, les systèmes de prédiction et les systèmes de recommandation [27].

II.3.2.2 Apprentissage non supervisé

L'apprentissage non supervisé est une méthode dans laquelle les données d'entraînement ne sont pas étiquetées. L'algorithme explore de manière autonome les données afin d'en extraire des structures cachées, des regroupements ou des relations intrinsèques. Son objectif principal est d'identifier des groupes d'éléments similaires pour mieux comprendre et organiser des ensembles de données complexes. Parmi ses applications figurent le clustering, l'estimation de densité ainsi que la réduction de dimension via des méthodes telles que l'ACP ou t-SNE [27].

II.4 Base de données utilisée

Afin d'évaluer les performances du système de reconnaissance faciale du genre proposé, nous avons utilisé une base de données extraite de la base FERET. Cette base est largement utilisée dans le domaine de la reconnaissance faciale grâce à la diversité des visages qu'elle contient ainsi qu'aux variations d'éclairage, d'expression et de pose [17].

Dans notre travail, nous avons retenu un ensemble de 836 images faciales réparties en deux classes de genre : masculin et féminin. Chaque classe contient 418 images, ce qui permet d'obtenir une base de données équilibrée et adaptée à l'apprentissage des différents classificateurs étudiés. Quelques images faciales de la base sont illustrées sur la figure 2.2.



Figure II.2 : Exemples d'images faciales de la base de données FERET

Pour les besoins de l'expérimentation, la base de données a été divisée en deux sous-ensembles : une base d'apprentissage utilisée pour la construction des modèles de classification et une base de test utilisée pour l'évaluation des performances du système.

Chaque sous-ensemble contient 209 images masculines et 209 images féminines.

Le tableau II.1 présente la répartition des images utilisées dans les phases d'apprentissage et de test.

Classe	Apprentissage	Test	Totale
Male	209	209	418
Female	209	209	418
Totale	418	418	836

Tableau II.1 : Répartition des données d'apprentissage et de test

II.5 Description des étapes du fonctionnement du système RFG

Le système de reconnaissance faciale du genre repose sur deux opérations majeures : l'extraction des caractéristiques et la classification. Dans la phase d'apprentissage, chaque image faciale est convertie en vecteur de caractéristiques HOG ou LBP, ce qui permet de réduire la complexité des données et de constituer une matrice d'apprentissage représentant les deux classes H et F. Lors de la phase de test, le vecteur extrait de l'image faciale est soumis au classificateur, qui le compare à la matrice d'apprentissage ou le modèle de classe afin de déterminer automatiquement la classe correspondante. La démarche de conception et d'implémentation du système se structure en étapes successives :

- Préparation des données d'apprentissage et de test
- Prétraitement des images faciales
- Extraction des caractéristiques
- Construction de la matrice d'apprentissage
- Classification des images faciales en deux classes de genre
- Évaluation des performances du système sur la base de test

Dans notre travail, nous avons opté pour trois méthodes de classification : KNN (K-Nearest Neighbors), SVM (Support Vector Machine) et LDA (Linear Discriminant Analysis), combinées avec l'approche d'extraction de caractéristiques HOG (Histogram of Oriented Gradients) et LBP (Local Binary Pattern).

Le diagramme de notre système RFG implémenté est illustré sur la Figure II.3 :




Figure II.3 : Diagramme fonctionnel du système RFG implémenté.

II.5.1. Préparation des données d'apprentissage et de test

Cette étape constitue le point de départ du système de reconnaissance faciale du genre (RFG). Elle consiste à diviser la base de données en deux ensembles distincts : un ensemble d'apprentissage, utilisé pour l'entraînement des classificateurs, et un ensemble de test, destiné à l'évaluation des performances du système. Pour garantir l'objectivité des résultats, un découpage équilibré à 50 % a été adopté entre les phases d'apprentissage et de test. Dans ce travail, une approche globale a été privilégiée : chaque image faciale est traitée dans son ensemble, sans décomposition en régions locales, puis soumise à un prétraitement avant l'extraction des caractéristiques.

II.5.2 Prétraitement des images faciales

Le prétraitement des images faciales constitue une étape essentielle avant l'extraction des caractéristiques, car il permet d'uniformiser les données et d'améliorer la performance du système de reconnaissance faciale du genre. Dans ce travail, les images sont d'abord converties en niveaux de gris afin de réduire la complexité tout en conservant les informations pertinentes. Une détection du visage est ensuite appliquée pour isoler la région faciale et éliminer les zones non pertinentes. Les visages détectés sont redimensionnés à une taille fixe afin de garantir

l'homogénéité des données d'entrée. Enfin, une normalisation est réalisée pour réduire les variations d'illumination et améliorer la qualité des images. Ces opérations produisent des données homogènes et adaptées à l'étape suivante, où les descripteurs HOG et LBP sont utilisés pour l'extraction des caractéristiques.



Figure II.4 : Etape de prétraitement

II.5.3 Extraction des caractéristiques

L'extraction des caractéristiques constitue une étape déterminante du système proposé, dans la mesure où elle permet de transformer l'image faciale prétraitée en un vecteur numérique exploitable par les classificateurs. Deux descripteurs ont été retenus dans le travail : l'Histogramme des Gradients Orientés (HOG) et le Local Binary Pattern (LBP), choisis pour leur complémentarité et leur efficacité reconnue dans les tâches de reconnaissance faciale.

II.5.3.1 Histogramme des gradients orientés (HOG)

L'Histogramme de Gradients Orientés (HOG) est un descripteur de caractéristiques utilisé en vision par ordinateur pour la détection d'objets, qui fonctionne en caractérisant l'apparence et la forme locale d'un objet par la distribution des directions des gradients d'intensité ou des contours. Concrètement, l'image est divisée en petites régions appelées "cellules", pour lesquelles un histogramme unidimensionnel des directions de gradients est accumulé pour chaque pixel. Afin d'améliorer la résistance aux variations d'éclairage et d'ombrage, ces résultats sont normalisés par rapport au contraste en regroupant les cellules en "blocs" plus larges et en utilisant l'énergie locale du bloc pour ajuster les valeurs. Le vecteur final, résultant de la concaténation de ces blocs normalisés, fournit une représentation robuste qui conserve l'essentiel des formes tout en ignorant les détails non pertinents comme la couleur des vêtements ou le fond [28].




Figure II.5 : Histogramme de gradients orientés

Voilà les principales caractéristiques du HOG :

Gradient :

Les deux composantes I_x et I_y du gradient de l'image I sont approximées par différences centrales :

$$I_x(r, c) = I(r, c + 1) - I(r, c - 1)$$

$$I_y(r, c) = I(r - 1, c) - I(r + 1, c) \quad \text{II.1}$$

Bien que la convolution avec la dérivée d'un gaussien fournisse des dérivées plus précises en présence de bruit, le lissage qu'elle implique éliminerait des détails utiles. De plus, un certain lissage du bruit se produit naturellement lors du calcul ultérieur des histogrammes de gradients. Ainsi, le filtrage gaussien est à la fois moins bénéfique et inutilement coûteux. Le gradient est ensuite converti en coordonnées polaires, l'angle étant contraint entre 0 et 180 degrés afin que des gradients de directions opposées soient associés au même angle :

$$\mu = \sqrt{I_x^2 + I_y^2} \text{ et } \theta = \frac{180}{\pi} (\text{atan2}(I_y, I_x) \bmod \pi) \quad \text{II.2}$$

Où atan2 désigne l'arc-tangente à quatre quadrants, dont le résultat est compris entre $-\pi$ et π .

Histogrammes d'orientation par cellule :

La fenêtre est divisée en cellules adjacentes et non chevauchantes de taille $C \times C$ pixels (avec $C=8$). Dans chaque cellule, on calcule un histogramme des orientations du gradient, regroupées en B cases (avec $B=9$). Avec un nombre aussi restreint de cases, un pixel dont l'orientation est proche d'une limite entre deux cases risquerait de basculer dans une case différente en cas de légère modification de l'image. Pour éviter ces artéfacts de quantification, chaque pixel d'une cellule contribue à deux cases adjacentes (modulo B) d'une fraction de son amplitude de gradient μ qui décroît linéairement avec la distance entre l'orientation du gradient de ce pixel et les centres des deux cases concernées [28].

Normalisation par blocs :

On regroupe les cellules en blocs qui se chevauchent de 2×2 cellules (taille $2C \times 2C$ pixels). Le décalage entre blocs est de C pixels, donc chaque cellule interne appartient à quatre blocs. Pour chaque bloc, on concatène les quatre histogrammes des cellules en un vecteur b , puis on le normalise par sa norme euclidienne :

$$b = \frac{b}{\sqrt{b^2 + \varepsilon}} \quad \text{II.3}$$

(ε évite la division par zéro).

Ce choix est purement empirique. Cette normalisation fait un compromis : elle réduit les variations de contraste tout en conservant les amplitudes relatives des gradients à l'intérieur d'un bloc. Comme chaque cellule est couverte par plusieurs blocs, chaque histogramme est normalisé de plusieurs façons différentes.

Caractéristique HOG :

Tous les descripteurs de blocs normalisés sont rassemblés en un seul vecteur h . Celui-ci subit une première normalisation :

$$h = \frac{h}{\sqrt{h^2 + \varepsilon}} \quad \text{II.4}$$

Ensuite, chaque valeur h_n est limitée à un seuil $\tau=0,2$ (écrêtage), puis une seconde normalisation identique est appliquée. L'écrêtage évite que des gradients trop forts ne masquent les détails fins. La normalisation finale rend le descripteur indépendant du contraste global de l'image.

Le vecteur HOG final est la concaténation de tous les histogrammes des blocs. Par exemple, avec une fenêtre de 128×64 pixels, des cellules de 8×8 pixels et un pas de bloc de 8 pixels, on obtient $15 \times 7 \times 4 \times 9 = 3780$ valeurs. C'est un descripteur très riche (3780 nombres pour 8192 pixels). On peut aussi le voir comme une matrice de 420×9

Visuellement, chaque cellule de la fenêtre est représentée par un petit « camembert » à 18 tranches (9 paires opposées) : l'orientation et l'opacité de chaque paire indiquent l'importance du gradient dans cette direction. Le HOG ressemble à une carte de contours, mais avec une localisation approximative (à l'échelle de la cellule) et une conservation partielle des magnitudes. Ces propriétés lui confèrent une certaine robustesse aux petits changements géométriques et photométriques.

Enfin, l'utilisation d'une pyramide d'images lors de la détection atténue les détails indésirables (comme les éclaboussures de boue) qui pourraient tromper le détecteur HOG aux échelles fines [28].

II.5.3.2 Local Binary Patterns (LBP)

La méthode LBP (Local Binary Patterns) est une technique d'extraction de caractéristiques utilisée pour la reconnaissance faciale. Elle consiste à comparer chaque pixel avec ses voisins afin de générer un motif local représentant la texture de l'image. Ensuite, ces motifs sont transformés en histogrammes décrivant la distribution des textures dans différentes régions de l'image. Ces histogrammes sont ensuite concaténés pour former un vecteur de caractéristiques utilisé pour la classification des visages. Les résultats montrent que la méthode LBP est simple et rapide à calculer, tout en offrant de bonnes performances en reconnaissance faciale, notamment face aux variations d'illumination et aux changements d'expressions faciales [29].




Figure II.6 : Local Binary Patterns

L'opérateur LBP est défini mathématiquement comme suit :

$$LBP_{P,R}(X_C, Y_C) = \sum_{p=1}^P S(g_p - g_c) 2^{p-1} \quad \text{II.5}$$

Où g_c représente le niveau de gris du pixel central de coordonnées (X_C, Y_C) , g_p le niveau de gris de chaque pixel voisin, et $S(x)$ la fonction seuil définie par :

$$S(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad \text{II.6}$$

Une fois les codes LBP calculés pour tous les pixels, un histogramme est construit selon la formule :

$$h(i) = \sum_{x,y} B(LBP(x,y) = i) \quad \text{II.7}$$

Où $h(i)$ représente le nombre d'occurrences de chaque code i . Afin d'incorporer davantage d'informations spatiales, l'image est divisée en **petites régions**, un histogramme local est calculé pour chacune d'elles, puis tous ces histogrammes sont **concaténés** pour former un vecteur de caractéristiques global représentant l'image entière [30].

II.5.4 Classification

Une fois les caractéristiques extraites de chaque image faciale à l'aide des descripteurs HOG et LBP, les vecteurs obtenus sont organisés sous la forme d'une matrice d'apprentissage, où chaque ligne correspond à une image et chaque colonne à l'une des composantes du vecteur de caractéristiques associé, la même structure étant adoptée pour la base de test afin de garantir

une cohérence entre les données d'apprentissage et d'évaluation. Cette matrice est ensuite exploitée par l'étape de classification, qui consiste à attribuer à chaque image, sur la base de son vecteur de caractéristiques, une étiquette correspondant à l'une des deux classes de genre étudiées : masculin ou féminin. Trois classificateurs ont été évalués à cet effet, chacun reposant sur un principe de décision distinct : la machine à vecteurs de support (SVM), qui détermine l'hyperplan séparateur optimal maximisant la marge entre les deux classes ; l'analyse discriminante linéaire (LDA), qui projette les données dans un espace de dimension réduite maximisant la séparabilité entre classes ; et la méthode des k plus proches voisins (KNN), qui attribue à chaque image la classe majoritaire parmi ses k voisins les plus proches. Cette évaluation comparative permet d'identifier la configuration la plus performante pour la tâche de reconnaissance faciale du genre.

II.5.4.1 K plus proches voisins (KNN)

L'algorithme des k plus proches voisins (k-NN) est une méthode d'apprentissage basée sur les instances. Il évalue la similarité entre un document test et un ensemble de données d'apprentissage, puis détermine la catégorie du document en se référant aux k exemples d'apprentissage les plus similaires.

Dans cette approche, les ensembles d'apprentissage sont projetés dans un espace de caractéristiques multidimensionnel, qui est partitionné en régions selon les catégories des données d'apprentissage. Un point de cet espace est attribué à la catégorie la plus fréquente parmi ses k plus proches voisins.

Dans notre système, la classification est réalisée avec la distance euclidienne et un paramètre K=1 (par défaut). Plusieurs mesures de similarité ou de distance peuvent être utilisées pour comparer deux vecteurs de n composantes. Les principales sont [1]:

- 'Euclidean', distance euclidienne :

$$d(X, Y) = \sqrt{\sum_{k=1}^M (x_k - y_k)^2} \quad \text{II.8}$$

- 'cityblock', somme des différences absolues :

$$d(X, Y) = \sum_{k=1}^k |x_k - y_k| \quad \text{II.9}$$

- 'cosine', cette distance est définie comme suit :

$$d(X, Y) = \frac{\sum_i x_i y_i}{\sqrt{\sum_i x_i^2} \sqrt{\sum_i y_i^2}} \quad \text{II.10}$$

- 'correlation', elle est donnée par :

$$d(X, Y) = \frac{N \sum xy - (\sum x)(\sum y)}{\sqrt{[N \sum x^2 - (\sum x)^2][N \sum y^2 - (\sum y)^2]}} \quad \text{II.11}$$

L'efficacité du k-NN repose sur la disponibilité d'une mesure de similarité adaptée pour identifier les voisins d'un document donné.

Phase d'apprentissage : Seuls les vecteurs de caractéristiques et les étiquettes de catégories des données d'apprentissage sont stockés.

Phase de classification : Les distances entre le vecteur du nouveau document et tous les vecteurs stockés sont calculées, puis les k échantillons les plus proches sont sélectionnés. La catégorie prédite est celle du voisin le plus proche, ou déterminée par un vote majoritaire parmi les k voisins, comme l'indique l'équation :

$$\text{Arg max } \sum_{j=1}^k \text{sim}\left(\frac{D_j}{D}\right) * \delta(C(D_j), i) \quad \text{II.12}$$

Où $\text{sim}(D, D_j)$ est la similarité entre le document test D et un voisin D_j , et δ est une fonction indicatrice qui vaut 1 si la catégorie du voisin correspond à la catégorie i . Le document test est alors affecté à la classe qui contient la majorité de ses voisins [31].




Figure II.7 : Illustration du principe K-Nearest Neighbors (KNN)

II.5.4.2 Machine à vecteurs de support (SVM)

La Support Vector Machine (SVM) est une méthode d'apprentissage supervisé destinée aux problèmes de classification et de reconnaissance de formes. Introduite par les réseaux à vecteurs de support (Support-Vector Networks), cette technique vise à déterminer une frontière de décision optimale séparant les différentes classes de données.

Le principe fondamental de la SVM consiste à rechercher un hyperplan optimal qui maximise la marge entre les classes. Cette approche améliore la capacité de généralisation du modèle et réduit les erreurs de classification sur des données inconnues.

L'hyperplan de séparation s'écrit sous la forme :

$$\mathbf{w}^T \mathbf{x} + \mathbf{b} = 0 \quad \text{II.13}$$

Où $\mathbf{w}$ est le vecteur normal à l'hyperplan et $\mathbf{b}$ le biais du modèle [32].

Lorsqu'un problème n'est pas linéairement séparable dans l'espace d'entrée, le SVM à marge molle ne parvient pas à trouver un hyperplan robuste ; l'utilisation d'un noyau permet alors de projeter les données dans un espace de plus grande dimension (espace noyau) où elles deviennent linéairement séparables, avec un surcoût de calcul mineur comparé à l'apprentissage d'une surface non linéaire. Un noyau doit être une matrice hermitienne semi-définie positive et satisfaire le théorème de Mercer, ce qui revient à ce que la matrice de Gram associée soit semi-définie positive. Parmi les noyaux courants figurent le noyau linéaire (adapté aux grandes données creuses), polynomial (évite l'annulation du Hessien, très utilisé en traitement d'images), sigmoïde, RBF gaussien et Laplacien (noyaux généralistes en l'absence de connaissances a priori), ANOVA RB (plutôt pour la régression) et spline linéaire en 1D. Le choix du noyau dépend fortement des données ; une matrice diagonale indique une redondance et nécessite de changer de noyau après réduction de caractéristiques. Enfin, pour les grands volumes de données, le calcul de la matrice noyau exige des ressources mémoire et de calcul importantes [33].




Figure II.8 : Machine à vecteurs de support

II.5.4.3 L'analyse discriminante linéaire (LDA)

L'analyse discriminante linéaire (LDA) est une méthode de classification supervisée qui vise à réduire la dimensionnalité des données tout en séparant au mieux deux ou plusieurs classes. Elle fonctionne en cherchant une combinaison linéaire de variables (une direction dans l'espace des caractéristiques) qui maximise la distance entre les moyennes des classes tout en minimisant la dispersion à l'intérieur de chaque classe. Concrètement, on projette les données sur un axe défini par un vecteur unitaire de façon à ce que le rapport entre la variance inter-classes et la variance intra-classes soit le plus grand possible ; cet axe optimal est obtenu en calculant le vecteur propre associé à la plus grande valeur propre de la matrice de dispersion [34].

II.5.5 Evaluation des performances

L'évaluation des performances constitue l'étape finale du système de reconnaissance faciale du genre. Elle vise à mesurer la capacité des classificateurs entraînés à généraliser correctement sur les images de la base de test, qui n'ont pas été utilisées durant la phase d'apprentissage.

Dans ce travail, la performance du système est évaluée à l'aide du taux de reconnaissance (Accuracy), défini comme le rapport entre le nombre d'images correctement classifiées et le nombre total d'images de la base de test. Cette mesure, exprimée en

pourcentage, permet d'apprécier la capacité du système à attribuer correctement le genre (masculin ou féminin) à de nouvelles images.

L'évaluation est réalisée pour les différentes combinaisons des descripteurs HOG et LBP avec les classificateurs KNN, LDA et SVM. Les résultats obtenus permettent d'effectuer une comparaison objective des différentes configurations étudiées et d'identifier la solution offrant les meilleures performances en termes de précision de classification.

II.6 Conclusion

Ce chapitre a présenté les notions théoriques essentielles sur lesquelles repose notre système de reconnaissance faciale du genre : les concepts du Machine Learning et ses principaux paradigmes, avec un accent particulier sur l'apprentissage supervisé, approche la plus adaptée à notre problème de classification, ainsi que l'architecture générale du système et ses différentes étapes de traitement, allant du prétraitement des images jusqu'à la phase de classification. Les descripteurs HOG et LBP ont été présentés comme méthodes d'extraction de caractéristiques permettant de représenter efficacement les informations des images faciales, et les modèles de classification utilisés dans notre travail, à savoir KNN, SVM et LDA, ont été décrits en soulignant leurs principes de fonctionnement ainsi que leurs différences en termes de performance et de complexité.

Le chapitre suivant sera consacré à l'implémentation de ces méthodes sur une base de données de visages, ainsi qu'à l'évaluation et la comparaison de leurs performances en termes de taux de classification.

Chapitre III

Evaluation et résultats

III.1 Introduction

La reconnaissance automatique du genre à partir d'images faciales représente un axe de recherche en plein essor dans le domaine de la vision par ordinateur et de l'intelligence artificielle. Cette tâche trouve des applications dans de nombreux secteurs, notamment la biométrie, la vidéosurveillance, le marketing ciblé et les interfaces homme-machine. Dans le cadre de ce travail, nous proposons un système de reconnaissance faciale du genre (RFG) fonctionnant en mode indépendant de la personne. L'approche proposée s'appuie sur les descripteurs HOG (Histogram of Oriented Gradients) et LBP (Local Binary Patterns) comme méthodes d'extraction de caractéristiques, reconnus pour leur robustesse dans la représentation des contours et des textures des visages. Ces descripteurs sont combinés avec trois algorithmes de classification distincts, à savoir KNN (K-Nearest Neighbors), SVM (Support Vector Machine) et LDA (Linear Discriminant Analysis), dans le but d'effectuer une analyse comparative rigoureuse de leurs performances respectives.

Dans cette étude, nous cherchons à répondre aux questions suivantes :

1. Quel classificateur parmi KNN, SVM et LDA offre les meilleures performances en termes de taux de reconnaissance du genre ?
2. Comment le choix de la métrique de distance (Euclidienne, City block,) et la valeur optimale de K influence-t-il les performances du classificateur KNN, notamment en termes de compromis entre biais et variance ?
3. Quel type de noyau (linéaire, RBF, polynomial) permet d'obtenir les meilleures performances du SVM à partir des descripteurs HOG ?
4. Dans quelle mesure le descripteur HOG est-il adapté à l'extraction des caractéristiques discriminantes pour la reconnaissance du genre facial, et quelles sont ses limites ?
5. Quelle combinaison entre le descripteur HOG et l'un des trois classificateurs produit les meilleurs résultats globaux sur la base de test ?
6. Quels sont les hyper-paramètres et la configuration optimale du système RFG permettant de maximiser le taux de reconnaissance tout en minimisant le temps de traitement ?
7. Le descripteur LBP permet-il d'améliorer les performances du classificateur KNN pour la reconnaissance faciale du genre ?

L'ensemble de ces questionnements guide notre démarche expérimentale, dont l'objectif final est d'identifier la configuration optimale du système RFG, garantissant un équilibre entre précision de classification et efficacité computationnelle.

III.2 Protocole d'évaluation utilisé

Dans notre travail, le protocole d'évaluation adopté repose sur un partage fixe des données en deux sous-ensembles distincts : un ensemble d'entraînement (**Training**) et un ensemble de test (**Test**). Chaque classe (Male / Female) contient **209 images** par sous-ensemble, ce qui correspond à une répartition équilibrée de **50% pour l'entraînement** et **50% pour le test**.

La métrique d'évaluation utilisée est le taux de reconnaissance (**Accuracy**), définie comme suit :

$$\text{Accuracy} = \frac{\text{Nombre d'images correctement classifiées}}{\text{Nombre total d'images testées}} \times 100 \quad \text{III.1}$$

Cette répartition équilibrée entre les deux classes garantit une évaluation objective et non biaisée des performances des différents classifieurs utilisés.

III.3 Expérimentations et Résultats

III.3.1 Environnement de travail

Les expérimentations réalisées dans ce travail ont été effectuées sur un environnement matériel et logiciel décrit ci-dessous :

III.3.1.1 Environnement matériel

Un ordinateur HP avec les caractéristiques suivantes :

- Processeur : Intel(R) Core(TM) i7-8750H CPU @ 2.20GHz 2.21 GHz.
- Mémoire RAM : 16,0 Go.
- OS : Système d'exploitation 64 bits, processeur x64.

III.3.1.2 Environnement logiciel :

- ✓ **L'environnement de programmation utilisé est MATLAB R2016b**

L'outil de développement utilisé est **MATLAB R2016a**. La plateforme MATLAB est optimisée pour résoudre les problèmes scientifiques et techniques. Son langage, basé sur le

calcul matriciel, constitue le moyen le plus naturel pour exprimer les mathématiques computationnelles. Il dispose de plusieurs boîtes à outils, en particulier **l'Image Processing Toolbox**, qui propose un ensemble d'algorithmes et d'outils graphiques permettant de traiter, analyser, visualiser et développer des algorithmes de traitement d'images. De plus, ses graphiques intégrés facilitent la visualisation des données afin d'en dégager des informations pertinentes.

III.3.2 Expériences et résultats

Avant de présenter les différentes expériences réalisées, nous exposons les principaux objectifs poursuivis à travers ces expérimentations. Celles-ci visent à évaluer les performances du système de reconnaissance faciale du genre en étudiant l'influence des descripteurs de caractéristiques et des classificateurs utilisés. Elles permettent également d'identifier la configuration la plus performante en termes de taux de classification afin d'améliorer l'efficacité du système proposé.

1. Expérience1 : Meilleure configuration du classificateur SVM

Dans cette expérience, notre objectif est de déterminer la meilleure configuration du classificateur SVM pour la reconnaissance du genre facial à partir des caractéristiques extraites par le descripteur HOG. Pour cela, plusieurs noyaux du SVM ont été évalués, notamment les noyaux linéaire, RBF et polynomial, en faisant varier la taille des images ainsi que la taille des cellules HOG.

Tout d'abord, nous avons testé le noyau linéaire (Linear) sur plusieurs configurations afin d'évaluer l'influence de la taille des images et des cellules HOG sur les performances du système. Les expériences ont été réalisées avec différentes tailles d'images (32×32 , 64×64 , 128×128 et 256×256) ainsi qu'avec plusieurs tailles de cellules HOG allant de 1×1 jusqu'à 8×8 .

Tailles de Cellules Taille d'images	1×1	2×2	3×3	4×4	5×5	6×6	7×7	8×8
32×32	55.98	80.14	83.25	83.97	83.49	85.17	85.89	84.21
64×64	61	78.95	83.73	86.36	87.32	85.41	87.8	89
128×128	59.09	77.27	81.34	83.49	88.52	88.28	92.11	92.58
256×256	56.7	76.79	80.38	82.78	88.52	90.43	90.91	93.78

Tableau III.1 : Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau linéaire pour différentes tailles d'images et tailles de cellules HOG.

Selon le Tableau III.1, les résultats obtenus montrent une amélioration progressive du taux de reconnaissance avec l'augmentation de la taille des images et l'utilisation de cellules HOG plus adaptées. Le meilleur résultat obtenu avec le noyau linéaire est de 93.78 %, atteint pour une taille d'image de 256×256 pixels et une taille de cellules HOG de 8×8.

Après l'analyse du noyau linéaire, nous avons appliqué la même démarche expérimentale aux noyaux RBF et polynomial afin de comparer leurs performances et de déterminer la configuration optimale du classificateur SVM.

Le tableau III.2 présente taux de reconnaissance obtenus avec le classificateur SVM à noyau RBF pour différentes tailles d'images et tailles de cellules HOG.

Tailles de cellules Taille d'images	1 × 1	2 × 2	3 × 3	4 × 4	5 × 5	6 × 6	7 × 7	8 × 8
32×32	54.31	76.32	83.97	88.28	87.56	87.80	87.80	87.56
64×64	61.72	81.10	85.41	89.23	87.32	87.32	90.19	89.95
128×128	63.16	80.86	84.93	88.52	89.71	90.67	91.15	93.30
256×256	61.72	83.49	84.93	89.47	90.43	90.19	92.34	94.50

Tableau III.2: Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau RBF pour différentes tailles d'images et tailles de cellules HOG.

D'après le **tableau III.2** on remarque que le taux de reconnaissance augmente avec le nombre de régions utilisées, Pour une image de 256×256 pixels, la précision passe de 61,72 % lorsqu'une seule région est utilisée jusqu'à 94,50 % avec huit régions. Cette amélioration est également observée pour les tailles 64×64 et 128×128 pixels. Nous avons trouvé que le meilleur résultat est obtenu avec une taille d'image de 256×256 et une taille de cellule HOG de 8×8 , avec un taux de reconnaissance de 94,5 %.

Le **tableau III.3** présente taux de reconnaissance obtenus avec le classificateur SVM à noyau Polynomial pour différentes tailles d'images et tailles de cellules HOG

Tailles de cellules Taille D'images	1 × 1	2 × 2	3 × 3	4 × 4	5 × 5	6 × 6	7 × 7	8 × 8
32×32	59.33	73.92	80.62	82.30	84.45	86.84	88.52	86.84
64×64	66.27	77.99	84.69	85.41	89.23	85.41	88.28	89
128×128	66.75	79.43	81.82	88.04	87.32	89	89.23	91.63
256×256	64.83	81.82	81.58	87.32	89.71	89.95	91.39	92.11

Tableau III.3: Taux de reconnaissance (%) obtenus avec le classificateur SVM à noyau Polynomial pour différentes tailles d'images et tailles de cellules HOG.

A partir des résultats de **tableau III.3** nous remarquons que le meilleur taux de reconnaissance est égal à 92.11%. Ce taux est obtenu avec une taille d'image de 256×256 pixels et une taille de cellule HOG de 8×8 .

Afin de déterminer le noyau le plus performant, nous avons réalisé une comparaison des résultats obtenus, présentée dans le **tableau III.4** :

Noyaux	Size	cell	Précision (%)
Linear	256x256	8x8	93.78
Rbf	256x256	8x8	94.5
Polynomial	256x256	8x8	92.11

Tableau III.4: Comparaison des performances des noyaux SVM avec la configuration optimale du descripteur HOG.

Les résultats obtenus montrent que les performances du système dépendent principalement des paramètres utilisés. L'augmentation du nombre de régions permet d'améliorer la précision, car elle offre une meilleure extraction des caractéristiques locales. De plus, la comparaison des noyaux SVM montre que le noyau RBF donne les meilleurs résultats avec 94,5 %, suivi du noyau linéaire et du noyau polynomial.

2. Expérience2 : Optimisation du classificateur KNN

L'objectif de cette expérience est d'évaluer les performances du classificateur KNN appliqué à la reconnaissance du genre facial à partir des caractéristiques extraites par le descripteur HOG. Afin d'identifier la configuration optimale, plusieurs valeurs de K ont été testées en combinaison avec différentes métriques de distance, telles que l'euclydienne, la city block et la cosine.

Dans le cadre de cette étude, nous avons évalué les performances du classificateur KNN en analysant l'influence de la taille des images ainsi que de la taille des cellules HOG sur les résultats de classification. Les tests sont réalisés avec $K = 1$ et la distance euclidienne. Les résultats obtenus sont présentés dans le tableau suivant :

Cellule HOG	32x32	64x64	128x128	256x256
1x1	54.31	60.53	61.24	60.29
2x2	75.36	73.21	79.19	79.43
3x3	79.90	79.19	82.30	77.75
4x4	76.32	79.67	80.14	78.95
5x5	78.71	81.10	80.14	81.10
6x6	79.67	79.43	83.25	82.30
7x7	81.10	82.30	82.78	83.01
8x8	81.34	83.25	82.06	82.06

Tableau III.5 : Influence de la taille des images et de la taille des cellules HOG sur les performances du KNN.

Selon les résultats présentés dans le **tableau III.5**, on observe que les taux de reconnaissance changent selon la taille de l'image et le nombre de divisions du visage. Les meilleures performances sont obtenues avec les configurations 64×64–8×8 et 128×128–6×6, qui atteignent un taux de reconnaissance de 83,25 %. Pour la suite, la configuration 128×128–6×6 a été retenue puisqu'elle fait partie des configurations ayant obtenu la meilleure précision.

Le choix de cette configuration est basé sur les résultats expérimentaux, puisqu'elle donne le meilleur taux de reconnaissance (83,25 %). Cette configuration permet une bonne extraction des caractéristiques HOG sans trop de perte d'information ni augmentation inutile de la complexité.

Dans cette étape, la configuration optimale du descripteur HOG précédemment déterminée (taille d'image 128×128 et taille de cellule 6×6) a été conservée afin d'évaluer et

de comparer les performances des différentes métriques de distance du classificateur KNN, à savoir les distances Euclidienne, City Block, Cosine et Correlation.

Distance	Euclidienne	Correlation	Cosine	City block
K optimal	4	4	3	4
TC (%)	84.21%	84.69%	82.06%	83.49%

Tableau III.6 : Influence de la métrique de distance sur les performances du classificateur KNN.

D'après les résultats présentés dans le **tableau III.6**, les performances du classificateur KNN varient en fonction de la métrique de distance utilisée. La distance de corrélation se distingue comme la plus performante, avec un taux de reconnaissance de 84,69 % pour un K optimal de 4. La distance euclidienne affiche des performances très proches (84,21 %, K = 4), tandis que la distance city block obtient un taux légèrement inférieur (83,49 %, K = 4). En revanche, la distance cosine enregistre la performance la plus faible (82,06 %, K = 3). Ces résultats soulignent l'importance du choix de la métrique de distance dans l'efficacité du KNN. Ainsi, la configuration optimale retenue pour la suite des expérimentations est celle basée sur la corrélation avec K = 4, garantissant le meilleur compromis entre précision et stabilité du modèle.

III. Expérience3 : Évaluation du classificateur LDA

Dans cette expérience, nous évaluons les performances du classificateur LDA (Linear Discriminant Analyses) pour la reconnaissance du genre facial à partir des caractéristiques extraites par le descripteur HOG. L'objectif est d'analyser la capacité de LDA à séparer linéairement les classes homme et femme et à mesurer son efficacité pour cette tâche de classification.

Le tableau suivant présente les taux de reconnaissance obtenus par le classificateur LDA combiné au descripteur HOG, en faisant varier la taille des images (32, 64, 128, 256) ainsi que le nombre de régions (1×1 à 8×8).

Size	1x1	2x2	3x3	4x4	5x5	6x6	7x7	8x8
32x32	58.13	80.38	80.86	82.30	77.75	78.47	62.92	74.64
64x64	67.46	81.10	83.25	84.93	82.30	76.08	67.22	77.03
128x128	67.46	81.10	85.41	89.47	85.89	73.68	61.72	80.14
256x256	65.31	83.25	84.93	90.19	86.12	71.53	61.72	81.34

Tableau III.7 : Influence de la taille des images et des cellules HOG sur les performances du classificateur LDA.

D'après les résultats présentés dans le **tableau III.7**, les performances du classificateur LDA évoluent en fonction de la taille des images et des cellules HOG. Pour les petites images (32×32), le taux de reconnaissance reste limité, avec un maximum de 82,30 % en configuration 4×4. L'augmentation de la taille améliore progressivement les résultats : 64×64 atteint 84,93 %, et 128×128 permet d'obtenir 89,47 % avec 4×4 cellules. La meilleure performance est enregistrée avec la configuration 256×256 – 4×4, qui atteint 90,19 %, représentant le compromis optimal entre richesse de la description locale et capacité discriminante du LDA. Au-delà de ce découpage, notamment avec des configurations plus fragmentées (6×6 ou davantage), les performances diminuent, ce qui suggère qu'une sur-partition de l'image dilue l'information pertinente.

La même configuration a été utilisée avec le classificateur Diaglinear. Les résultats sont présentés dans le **tableau III.8** :

Size	1x1	2x2	3x3	4x4	5x5	6x6	7x7	8x8
32x32	55.74	73.68	75.6	75.6	75.75	77.51	78.71	77.75
64x64	59.09	73.68	73.44	74.64	75.6	77.99	78.95	78.47
128x128	56.94	74.88	72.49	75.36	77.75	78.23	80.14	80.62
256x256	58.37	76.08	75.12	79.43	80.14	82.78	86.84	87.80

Tableau III.8 : Résultats du classificateur Diaglinear avec la même configuration HOG

D'après les résultats présentés dans le tableau, les performances du classificateur LDA varient selon la taille des images et la taille des cellules HOG. Pour les petites images (32×32), le taux de reconnaissance reste limité, avec un maximum de 78,71 % obtenu en configuration 7×7. L'augmentation de la taille des images améliore progressivement les résultats : pour 64×64, la précision atteint 78,95 % avec 7×7 cellules, tandis que les images de 128×128 dépassent 80 % avec un maximum de 80,62 % obtenu pour 8×8. La meilleure performance est enregistrée avec les images de 256×256, où le taux de reconnaissance atteint 87,80 % en 8×8

cellules. Ces observations montrent que l'amélioration des performances est plus marquée pour les grandes tailles d'images associées à un nombre élevé de cellules HOG.

La même configuration expérimentale a été utilisée avec le classificateur Pseudolinear. Les résultats obtenus sont présentés dans le tableau suivant :

Size	1x1	2x2	3x3	4x4	5x5	6x6	7x7	8x8
32x32	58.13	80.38	80.86	82.30	77.75	78.47	55.74	67.94
64x64	67.46	81.10	83.25	84.93	82.30	76.08	59.81	77.27
128x128	67.46	81.10	85.41	89.47	85.89	73.68	55.50	81.58
256x256	65.31	83.25	84.93	90.19	86.12	71.53	68.66	84.45

Tableau III.9 : Influence de la taille des images et de la taille des cellules HOG sur les performances du classificateur PseudoLinear.

D'après les résultats présentés dans le **tableau III.9** le classificateur Pseudo-Linear obtient sa meilleure performance avec une taille d'image de 256×256 et une taille de cellules HOG de 4×4, atteignant un taux de reconnaissance de 90,19 %. Ces résultats sont similaires à ceux obtenus avec le classificateur Linear, qui atteint également la même précision pour la même configuration. Cette convergence confirme l'efficacité de la configuration 256×256–4×4 pour la classification du genre facial à l'aide du classificateur LDA.

Le tableau suivant récapitule les meilleures configurations obtenues pour le classificateur LDA avec les trois noyaux testés (PseudoLinear, Diaglinear et Linear), en termes de taille d'image, de taille de cellule et de taux de reconnaissance.

	Pseudo Linear	diaglinear	Linear
Size	256	256	256
Cell	4x4	8x8	4x4
Précision	90.19	87.80	90.19

Tableau III.10 : Résultats des différents noyaux du LDA.

D'après le **tableau III.10** récapitulatif, il ressort que les noyaux PseudoLinear et Linear offrent les meilleures performances avec un taux de reconnaissance de 90.19%, tous deux obtenus pour une taille d'image de 256×256 et une taille de cellules de 4×4 régions. Le noyau Diaglinear, quant à lui, atteint un taux de 87.80% avec une configuration 256×256 / 8×8, demeurant légèrement inférieur aux deux autres. Par conséquent, nous retenons le noyau

PseudoLinear (ou Linear) avec la configuration $256 \times 256 / 4 \times 4$ comme configuration optimale du classificateur LDA pour la suite de nos expériences.

4. Expérience 4 : Analyse des performances temporelles

Cette section présente une étude du temps d'apprentissage et du temps de test afin d'évaluer les performances des classificateurs en termes de temps d'exécution. Les résultats obtenus sont résumés dans le tableau suivant :

Classificateur	Taux de reconnaissance (%)	Temps d'entraînement(s)	Temps de test(s)
SVM	94.50	0.0771	0.0199
KNN	84.69	/	0.0296
LDA	90.19	0.0508	0.0129

Tableau III.11 : Comparaison des performances temporelles des classificateurs.

A partir des résultats du **tableau III.11** nous remarquons que :

SVM : Avec une précision de 94,50 %, il se positionne comme le modèle le plus performant. Ses temps de calcul restent très faibles (0,0771 s pour l'entraînement et 0,0199 s pour le test), ce qui confirme sa robustesse et son efficacité dans la classification du genre facial.

LDA : Il atteint une précision satisfaisante de 90,19 %, tout en affichant les temps les plus rapides (0,0508 s et 0,0129 s). Ce compromis en fait une solution intéressante lorsque la rapidité d'exécution est prioritaire.

Les résultats montrent que le SVM représente le meilleur compromis entre précision élevée et efficacité computationnelle, ce qui en fait le choix privilégié pour une application fiable et robuste. Le LDA, bien que légèrement moins précis, reste une alternative pertinente pour des scénarios où la rapidité est essentielle.

5. Expérience 5 : Évaluation des performances du descripteur LBP associé au classificateur KNN

Cette expérience a pour objectif d'évaluer les performances du classificateur KNN associé au descripteur LBP en faisant varier le nombre de voisins K ainsi que la mesure de distance utilisée. Quatre métriques de distance ont été considérées : Euclidean, City block, Cosine et Corrélation. Les résultats obtenus en termes de taux de reconnaissance sont présentés dans le tableau suivant :

K	1	2	3	4	5	6	7	8	9	10
Euclidean	69.37	69.37	72.48	72.72	73.2	75.35	73.2	75.59	75.35	76.31
City block	71.53	71.53	72.72	75.83	75.35	74.16	74.16	75.83	74.88	76.07
Cosine	69.37	69.37	72.48	72.72	73.2	75.35	73.2	75.59	75.35	76.31
Correlation	68.42	68.42	73.44	72.48	74.4	74.88	73.92	75.11	73.44	74.16

Tableau III.12 : taux de reconnaissance (%) du classificateur KNN avec le descripteur LBP

L'analyse des résultats montre que les performances du classificateur KNN varient en fonction du nombre de voisins K et de la métrique de distance utilisée. Globalement, les meilleurs résultats sont obtenus pour K = 10 avec un taux de reconnaissance de 76,31 % pour la distance Euclidean et 76,07 % pour la distance City block. Les distances Euclidean et Cosine produisent des résultats identiques pour toutes les valeurs de K, tandis que la distance Corrélation présente les performances les plus faibles. Ces résultats indiquent que l'augmentation du nombre de voisins améliore généralement les performances jusqu'à atteindre une valeur optimale autour de K = 10.

III.4 Discussion

Cette section vise à interpréter les résultats obtenus lors des expérimentations présentées dans ce chapitre, en les confrontant aux questions de recherche initiales et en analysant les implications techniques des choix méthodologiques. L'objectif est de fournir une compréhension approfondie des performances des différents classificateurs (SVM, KNN, LDA) combinés au descripteur HOG pour la reconnaissance faciale du genre (RFG).

Les expérimentations ont permis d'évaluer et d'optimiser individuellement les classificateurs SVM, KNN et LDA. Une synthèse des meilleures performances de chaque classificateur est présentée ci-dessous :

Classificateur	taux de reconnaissance (%)	Cellule HOG	Taille d'image	Temps d'entraînement(s)	Temps de test(s)
SVM	94.50	8x8	256x256	0.0771	0.0199
KNN	84.69	6x6	128x128	/	0.0296
LDA	90.19	4x4	256x256	0.0508	0.0129

Tableau III.13 : Comparaison des performances des classificateurs.

Les résultats obtenus dans le **tableau III.13** montrent que le SVM avec un noyau RBF offre les meilleures performances globales, atteignant un taux de reconnaissance de 94,50 %. Cette supériorité s'explique par la capacité du noyau RBF à modéliser des frontières de décision non linéaires complexes, ce qui est particulièrement adapté à la variabilité inhérente aux données faciales (expressions, illumination et morphologie). Le descripteur HOG, en capturant les informations de gradient et d'orientation des contours, fournit des caractéristiques robustes que le SVM-RBF exploite efficacement pour distinguer les genres.

Le classificateur LDA se positionne en deuxième position avec un taux de reconnaissance de 90,19 %. Cette méthode cherche à maximiser la séparabilité entre les classes tout en minimisant la variance intra-classe. Les résultats obtenus montrent que les caractéristiques HOG possèdent une structure discriminante que le LDA parvient à exploiter efficacement. La meilleure configuration a été obtenue avec des images de 256×256 pixels et des cellules HOG de 4×4 .

Le classificateur KNN présente les performances les plus faibles parmi les trois approches évaluées, avec un taux de reconnaissance maximal de 84,69 %. Bien que sa simplicité constitue un avantage, sa dépendance aux distances dans l'espace des caractéristiques le rend plus sensible à la dimensionnalité des données et aux variations présentes dans les images. Malgré l'optimisation du paramètre K et de la métrique de distance, il ne parvient pas à égaler les performances du SVM ou du LDA pour cette application.

En réponse à la question de recherche relative au choix du classificateur le plus performant, les résultats montrent que le SVM avec noyau RBF constitue la meilleure solution. La combinaison optimale pour le système proposé est l'association du descripteur HOG avec le classificateur SVM-RBF, utilisant une taille d'image de 256×256 pixels et une taille de cellule de 8×8 . Cette configuration a permis d'atteindre un taux de reconnaissance de 94,50 %, confirmant son efficacité pour la reconnaissance du genre facial. En ce qui concerne la complexité computationnelle, le LDA se distingue par le temps de test le plus faible (0,0129 s), devançant le SVM (0,0199 s) et le KNN (0,0296 s), ce qui en fait une alternative intéressante pour les applications temps réel malgré une précision légèrement inférieure.

En complément de cette analyse des classificateurs, il est également pertinent d'examiner le rôle ainsi que les limites du descripteur HOG utilisé pour l'extraction des caractéristiques.

Le descripteur HOG s'est révélé pertinent pour la tâche de reconnaissance du genre facial, grâce à sa capacité à représenter efficacement les contours et les textures du visage en capturant des informations structurelles discriminantes telles que la forme de la mâchoire, la ligne des sourcils et les régions péri-orbitaires. Cependant, il présente certaines limites inhérentes à sa nature de descripteur de bas niveau : il demeure sensible aux variations d'illumination, aux occultations partielles et aux changements de pose extrêmes, et ne permet pas de modéliser des relations sémantiques complexes entre les différentes régions faciales. En perspective, les approches basées sur l'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN), constituent une alternative prometteuse permettant d'extraire automatiquement des caractéristiques de haut niveau plus robustes et mieux adaptées à la variabilité des données faciales en conditions réelles.

III.5 Étude comparative

Afin d'évaluer l'apport de notre système par rapport aux travaux existants, nous présentons dans ce qui suit une étude comparative entre nos résultats et ceux obtenus par **Ali & Baabouche [1]**, qui ont utilisé la base de données FERET avec le descripteur LBP et le classificateur KNN. Il est important de noter que dans notre travail, la base de données a été répartie de manière équilibrée (50 % pour l'apprentissage et 50 % pour le test), contrairement à l'étude de référence qui utilise une répartition de 75 % pour l'apprentissage et 25 % pour le test. Cette différence de protocole permet de mieux contextualiser les performances obtenues et d'évaluer la robustesse du système dans des conditions plus équilibrées.

References	Année	Descripteur	Classificateur	Distance	K	Meilleur TR (%)
Ali & Baabouche [1]	2020	LBP	KNN	Correlation	8	69.5
Notre travail	2026	LBP	KNN	Euclidean	10	76.31

Tableau III.14 : Etude comparative avec [1].

D'après les résultats du **tableau III.14** comparatif, notre système atteint un taux de reconnaissance de 76.31%, surpassant celui obtenu par **Ali & Baabouche [1]** qui est de 69.5%. Cette amélioration est obtenue en utilisant la distance Euclidean avec K=10, tandis que les

auteurs de référence ont opté pour la distance Correlation avec $K=8$. Ces résultats confirment que le choix de la configuration optimale du classificateur KNN a un impact direct sur les performances du système de reconnaissance faciale du genre.

D'autre part, afin de mieux situer les performances de notre approche, une comparaison a été réalisée avec le meilleur système obtenu dans cette étude, basé sur le descripteur HOG et le classifieur SVM. En comparant les résultats obtenus avec ceux de la combinaison LBP + KNN, on constate que le système HOG + SVM offre de meilleures performances, avec un taux de reconnaissance de 94,50 % contre 76,31 % pour le système LBP + KNN. Cette différence peut s'expliquer par la capacité du descripteur HOG à mieux représenter les contours et les gradients du visage, ainsi que par l'efficacité du classifieur SVM dans la séparation des classes. Cette comparaison permet de situer notre approche par rapport aux différentes configurations évaluées et met en évidence l'impact du choix du descripteur et du classifieur sur les performances de la reconnaissance du genre.

III.6 Conclusion

Ce chapitre a été consacré à l'évaluation des performances d'un système de reconnaissance du genre facial (RFG) basé sur le descripteur HOG combiné avec trois classificateurs, à savoir le SVM, le LDA et le KNN. L'étude a été menée sur la base de données FERET composée de 836 images réparties équitablement entre les classes masculin et féminin. Plusieurs expériences ont été réalisées dans le but de déterminer la meilleure configuration du système en fonction du taux de reconnaissance et du temps de traitement. Au travers des différentes expériences, nous avons montré que la meilleure performance est obtenue en utilisant le classificateur SVM avec noyau RBF associé au descripteur HOG, en fixant la taille d'image à 256×256 pixels et la taille de cellule à 8×8 , atteignant un taux de reconnaissance de 94,50 %. Le classificateur LDA s'est positionné en deuxième place avec 90,19 %, suivi du KNN avec 84,69%.

Par ailleurs, nous avons également évalué le descripteur LBP combiné avec le classificateur KNN sur la même base de données, où la meilleure configuration a permis d'atteindre un taux de reconnaissance de 76.31%. Ces résultats confirment la supériorité du descripteur HOG par rapport au LBP pour la tâche de reconnaissance faciale du genre, notamment lorsqu'il est associé à un classificateur performant tel que le SVM.

Conclusion générale

Dans le cadre de notre étude, nous avons développé un système automatique de reconnaissance faciale du genre (**RFG**) fonctionnant en mode indépendant de la personne. Ce système s'inscrit dans le domaine de la vision par ordinateur et de l'intelligence artificielle, et repose sur une approche combinant l'extraction de caractéristiques visuelles et la classification supervisée. L'architecture globale du système intègre trois modules fondamentaux interdépendants : un module de détection faciale, chargé de localiser et d'isoler la région d'intérêt dans l'image ; un module d'extraction de caractéristiques, basé sur les descripteurs **HOG** (Histogram of Oriented Gradients) et **LBP** (Local Binary Pattern), qui encodent respectivement les informations de gradient et de texture propres à chaque visage sous forme de vecteurs discriminants ; et enfin un module de classification, qui exploite ces vecteurs pour attribuer automatiquement le genre à chaque image faciale

Le système proposé opère selon deux phases complémentaires : une phase d'apprentissage, durant laquelle le modèle assimile les représentations caractéristiques des deux classes de genre à partir des données d'entraînement, et une phase de test, qui permet d'évaluer objectivement les capacités de généralisation du système sur des données inédites.

Pour mener cette étude, nous avons constitué manuellement une base de données propre, composée de 836 images faciales couvrant les deux genres (masculin et féminin), collectées dans des conditions variées afin d'assurer une certaine diversité. Cette base a été subdivisée en deux sous-ensembles égaux : **50%** alloués à l'apprentissage et **50%** réservés à l'évaluation.

Trois algorithmes de classification ont été évalués et comparés : **KNN** (K-Nearest Neighbors), **SVM** (Support Vector Machine) et **LDA** (Linear Discriminant Analysis), associés avec le descripteur **HOG**. Le descripteur **LBP** a également été testé en combinaison avec le classifieur KNN pour étude comparative. L'objectif central de cette étude est d'identifier la configuration optimale du système RFG, en déterminant le classificateur et le descripteur les plus performants.

Les résultats obtenus ont démontré que la meilleure configuration est celle du classificateur **SVM** avec noyau **RBF**, associé au descripteur **HOG** avec une taille d'image de **256×256** pixels et une cellule de **8×8**, atteignant un taux de reconnaissance de **94,50 %**. Le

classificateur **LDA**, avec une configuration de **256×256** pixels et une cellule de **4×4**, s'est positionné en deuxième place avec un taux de **90,19 %**, offrant un bon compromis entre précision et rapidité de traitement. Le classificateur **KNN**, avec une configuration de **128×128** pixels, une cellule de **6×6** et une distance de corrélation (**K=4**), a enregistré un taux de reconnaissance de **84,69 %** avec le descripteur **HOG**. La combinaison du descripteur **LBP** avec le classificateur **KNN** a quant à elle atteint un taux de reconnaissance de **76,31 %**, confirmant la supériorité du descripteur **HOG** pour cette tâche, tout en illustrant la complémentarité des deux descripteurs étudiés. Une étude comparative menée avec les travaux de **Ali et Baabouche (2020)**, qui ont obtenu un taux de reconnaissance de **69,5 %** avec la même configuration **LBP+KNN**, confirme la pertinence de notre approche et met en évidence une amélioration sensible des performances obtenues dans le cadre de ce travail.

Enfin, comme perspectives de cette étude, nous proposons de :

- ✓ Étendre l'évaluation du système à des bases de données plus larges et plus représentatives.
- ✓ Intégrer d'autres descripteurs de caractéristiques tels que BSIF et LPQ.
- ✓ Explorer des approches d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN), afin d'améliorer davantage les performances du système RFG

Bibliographie

- [1] F. & B. M. Ali, *Reconnaissance faciale du genre basée sur le descripteur LBP*, Université Mohamed El-Bachir El-Ibrahimi – Bordj Bou Arreridj: Mémoire de Master, 2020.
- [2] P. Kaur, K. Krishan, S. K. Sharma et T. Kanchan, «Facial-recognition algorithms: A literature review,» *Medicine, Science and the Law*, vol. 60, n° %12, pp. 131-139, 2020.
- [3] S. Z. Li et A. K. Jain, *Handbook of Face Recognition*, Springer, 2011.
- [4] W. X. ‘. H. G. C. A. R. I. J. o. B. V. N. 2. Xi Long, «Human Gender Classification: A Review,» *International Journal of Biometrics*, vol. 8, n° %13/4, 2016.
- [5] C. Shan, *Learning Local Binary Patterns for Gender Classification on Real-World Face Images,*” *Pattern Recognition Letters*, 2011.
- [6] W. Gao et . A. H. , *Face gender classification on consumer images in a multiethnic environment,,* 2009.
- [7] S. S. Liew, M. Hani, S. A. Radzi, et R. Bakhteri,, «Gender classification: a convolutional neural network approach,» *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 24, n° %13, pp. 1248-1264, 2016.
- [8] Vonintsoa, «Leguide complet de la reconnaissance faciale : IntelligenceArtificielle,» Mars 2022. [En ligne]. [Accès le juin 2026].
- [9] F. L. Y. Zhuang et WenyaoXu, «Human Gender Classification,» *A Review*, pp. pp. 275-300, 2017.
- [10] M. Agarwal, N. Jain,, M. M. Kumar, et . H. Agrawal,, « Face recognition using eigen faces and artificial neural network.,» *International Journal of Computer Theory and Engineering*, , vol. 2, n° %14, p. 624., 2010.
- [11] C. Zhang, H. Ding, , Y. Shang, , Z. Shao, et X. Fu, , «Gender classification based on multiscale facial fusion feature.,» *Mathematical Problems in Engineering*, vol. 2018, n° %11, p. 1924151, 2018.
- [12] C. Shan, «Learning local binary patterns for gender classification on real-world face images,» *Pattern recognition letters,,* vol. 33, n° %14, pp. 431-437, 2012.
- [13] M. S. S. & B. MAHBOUB, *EXTRACTION DES CARACTERISTIQUES POUR RECONNAISSANCE AUTOMATIQUE DES VISAGE*, Ouargla: Université KASDI MERBAH Ouargla, 2017.
- [14] A. Ahlem, «Réduction de la dimensionnalité pour l’amélioration des performances d’identification biométrique,» Université de Bordj Bou Arreridj, Bordj Bou Arréridj, 2018.
- [15] F. Lin, Y. Wu,, . Y. Zhuang, , X. Long, et W. Xu, , «Human Gender Classification: A Review,» *International Journal of Biometrics*, vol. 8, n° %13/4, p. 275–300, 2016.
- [16] I. & B. S. E. Benamiour, *Mise au point d’un système de reconnaissance de visage basée Arduino*, Jijel, 2019.
- [17] «face-recognition-technology-feret,» [En ligne]. Available: <https://www.nist.gov/programs-projects>. [Accès le 28 avril 2026].
- [18] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer,, 2006.
- [19] T. Hastie, R. Tibshirani, et . J. Friedman,, *the Elements of Statistical Learning.,* Springer, 2009.

- [20] A. K. Jain et al., J. Huang, *Integrating Independent Components and Linear Discriminant Analysis for Gender Classification*, 2004.
- [21] C. Shan., « Learning local binary patterns for gender classification on real-world face images,» *Article history: Available online*, 2011.
- [22] A. G. G. Azzopardi et V. M. , «Gender recognition from face images using a fusion of svm classifiers. In International Conference on Image Analysis and Recognition,» Springer International Publishing., Cham: , 2016.
- [23] M. Annalakshmi, S. Roomi, , . M. M. et . A. S. Naveedh., « hybrid technique for gender classification with SLBP and HOG features,» *Cluster Computing*, vol. 22, p. 11–20, 2019.
- [24] M. Irhebhude, A. O. Kolawole, et H. K. Goma, , «Agender recognition system using facial images with high dimensional data.,» *Journal of Applied Sciences*,, vol. 6, n° %11, pp. 27-45., 2021.
- [25] M. J. Al_Dujaili, H. T. Salim ALRikabi, et I. Niama ALRubeei, , «Gender Recognition of Human from Face Images Using Multi-ClassSupport Vector Machine (SVM) Classifiers.,» *International Journal of InteractiveMobile Technologies*, vol. 17, n° %18, 2023.
- [26] «Apprentissage automatique —Wikipédia,» [En ligne]. [Accès le 2026].
- [27] H. HADJER, *Apprentissage Supervisé Pour La Reconnaissance Facial Des Images à Basse Résolution (Doctoral dissertation)*, bordj bou arerid: university of bordj bou arerid, 2025.
- [28] C. .. H. o. O. G. [. d. c. Tomasi, *Histograms of Oriented Gradients [Notes de cours]*, Université Duke.: Département d'informatique, 2017, 18 septembre.
- [29] M. S. N. M. R. I. Md. Abdur Rahim, «e Recognition using Local Binary Patterns (LBP)'' ,» vol. 13, n° %14, 2013.
- [30] T. O. M. P. a. S. M. . Mäenpää, «Robust texture classification by subsets of local binary patterns. In Pattern Recognition,» *International Conference on*, vol. 3, pp. 39-47, 2000.
- [31] A. B. B. L. L. H. & K. K. Khan, «A review of machine learning algorithms for text-documents classification.,» *Journal of advances in information technology*,, vol. 1, n° %11, pp. 4-20, 2010.
- [32] C. Cortes and V. Vapnik, «“Support-Vector Networks,” ,» *Machine Learning*, vol. 20, n° %13, pp. 273–297,, 1995..
- [33] M. & K. R. Awad, «Support vector machines for classification.,» *n Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, pp. 39-66, 2015.
- [34] «GeeksforGeeks,» Linear Discriminant Analysis in Machine Learning, 13 September 2025. [En ligne]. [Accès le 2026].