

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي
Ministère de l'enseignement Supérieur et de la Recherche scientifique



Université Mohamed Khider Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique
Filière : **Electronique**
Option : **Télécommunication**

Réf:.....

Mémoire de Fin d'Etudes
En vue de l'obtention du diplôme:

MASTER

Thème

Etude comparative de PCA et KPCA associées au SVM en biométrie.

Présentée par :
DJEDI Sara
Soutenu le : 08 Juin 2012

Devant le jury composé de :

Mlle :TOUMI Abida

MAA

Présidente

Mme: BELAHCEN Mébarka

MAA

Encadrice

Mr :HEZABRA Adel

MAB

Examineur

Année universitaire : 2011 / 2012

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي
Ministère de l'enseignement Supérieur et de la recherche scientifique



Université Mohamed Khider Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique
Filière : **Electronique**
Option : **Télécommunication**

Mémoire de Fin d'Etudes
En vue de l'obtention du diplôme:

MASTER

Thème

*Etude comparative de PCA et KPCA associées au SVM pour
l'identification en biométrie.*

Présenté par :
DJEDI Sara

Avis favorable de l'encadreur :
BELAHCEN Mébarka

Avis favorable du Président du Jury

TOUMI Abida

Cachet et signature



Université Mohamed Khider Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique
Filière : **Electronique**
Option : **Télécommunication**

Thème :

Etude comparative de PCA et KPCA associées au SVM pour l'identification en biométrie.

Proposé par : BELAHCEN Mébarka

Dirigé par : BELAHCEN Mébarka

RESUME (bilingue)

Dans la littérature, on trouve plusieurs méthodes globales, locales et hybrides de reconnaissance de visages. Le but de ce projet est d'établir une étude comparative entre deux approches monomodales l'une basée sur l'Analyse en Composantes Principales (ACP) et la deuxième est une ACP à laquelle on associe un noyau (Kernel) pour mieux assurer la classification non linéaire. L'approche est basée sur un filtrage de Gabor dont les paramètres sont prise en considération dans l'amélioration des performances du système de reconnaissance de visages. Nous utilisons un classifieur à machines de vecteurs supports qui donne des résultats satisfaisants. Et l'étude comparative est menée entre une approche (PCA) et une approche KPCA associées à deux types de classifieurs SVM et mesures de distances. Le système de reconnaissance de visage à base de KPCA et SVM est réalisé sur la base de donnée XM2VTS et nous pouvons dire que le noyau PCA sur cette base donne de bons résultats surtout avec l'utilisation de filtre Gabor.

Mots clés : KPCA, PCA, XM2VTS, filtre Gabor et SVM

Dédicaces

Je dédie ce modeste travail,

A mon père Ahmed avec toute ma reconnaissance,

A ma mère Djamilia avec toute mon affection,

A ma sœur : Amina et son mari,

A mes frères Abas et Hamza,

À tous mes amis, *Soumia, Hanane, Nounou, Lamia*

Nihad et Zoubida pour leurs soutiens et leurs

encouragements.

Et à tout ma famille.

REMERCIEMENTS

En tout premier lieu, je remercie du plus profond de mon cœur ALLAH, tout Puissant, de m'avoir éclairé vers le bon chemin. Je tiens à remercier ma famille pour leur apport affectif et leurs sacrifices. Je ne saurais suffisamment remercier la personne qui m'a aidé à réaliser ce travail dans les meilleures conditions mon encadreuse Mme BELAHCENE BENATIA Mébarka. Ses compétences scientifiques, son excellente capacité pédagogique, sa disponibilité, sa patience tout au long de ce travail m'ont été bénéfique. Je tiens à remercier Mr OUAMANE AbdeIMalik et Raouf ALISMAIL pour leur aide.

Mes remerciements vont à : Souhila NAOUI, Azzedine, Yacine, Nadjib, GUENDOUZE Yousef et son père pour leurs aides et leurs encouragements.

Je remercie également le Président et les membres du Jury qui me font l'honneur d'accepter de juger mon travail .

Sans oublier bien entendu tous les enseignants qui ont contribué par leur savoir et leurs encouragements le long de mon parcours.

Liste des tableaux

Tab. I.1 Avantages et inconvénients de RV.....	11
Tab. IV.1 Application de KPCA dans la BDD évaluation avec le filtre Gabor	58
Tab. IV.2 Taux de reconnaissance pour N_p et σ variables dans les deux ensembles.....	59
Tab. IV.3 Taux de reconnaissance $N_p = 600$ et σ variable dans les deux ensembles.....	62
Tab. IV .4 La comparaison entre PCA et KPCA [Haf 11].....	63
Tab. IV. 5. Comparaison entre le KPCA et PCA par différentes Classifications.....	65

Listes de figures

Fig. I.1 : Comparaison entre les différentes biométries existantes, par rapport à leur coût et précision.....	5
Fig.I.2: L'effet Thatcher (d'après Thompson, 1980 qui avait utilisé une photographie de Margaret Thatcher dans son exemple initial).....	6
Fig.I.3: Schéma de vérification d'un visage.....	7
Fig.I.4: Le système de reconnaissance de visage.....	7
Fig.I.5: Exemple d'acquisition d'une image.....	7
Fig.I.6: Détection de visage.....	8
Fig.I.7: Exemple d'image d'apprentissage.....	10
Fig.I.8. Les méthodes de la reconnaissance de visage.....	15
Fig.I.9. Reconnaissance et identification dépendant des paramètres de points de vue.....	15
Fig. I.10. La reconnaissance automatique de visages est la technique d'authentification biométrique.....	16
Fig.II.1 Exemple de projection suivant PCA.....	21
Fig.II.2 Exemple d'Eigen Faces.....	23
Fig.II.3 Projection par LDA avec séparation entre les classes.....	26
Fig.II.4 Comparaison entre les projections de deux classes de points sur les axes principaux construits par PCA et par LDA.....	27
Fig.II.5 Frontière de décision obtenue grâce à la méthode KFD itérative.....	30
Fig.III.1 Organigramme du système de vérification d'identité de visage.....	32
Fig.III.2 Image converse au NG.....	33
Fig.III.3 l'image de visage avant et après découpage.....	34
Fig.III.4 l'effet de seuil dans chaque filtre.....	34
Fig.III.5 Orientation de l'ondelette.....	35
Fig.III.6 La fréquence centrale de l'ondelette (λ).....	36
Fig.III.7 Phase de l'ondelette.....	36
Fig.III.8 Support temporel de l'ondelette.....	37
Fig.III.9 Forme de l'enveloppe gaussienne.....	37
Fig.III.10 Séparation linéaire dans un espace à deux dimensions.....	40
Fig.III.11 Frontière de décision non linéaire.....	43

Listes de figures

Fig. IV.1 Organigramme d'apprentissage.....	47
Fig. IV.2 Organigramme de test.....	48
Fig. IV.3 Organigramme du système de vérification d'identité de visage.....	49
Fig. IV.4 Exemple de prétraitement d'une image.....	52
Fig. IV.5 Schéma fonctionnel de la KPCA	53
Fig. IV.6 Algorithme de calcul de TFA , FFR et seuillage.....	56
Fig. IV.7 La courbe du TR pour la KPCA avec Gabor pour L₂ et L₃	59
Fig IV.8 : Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble d'évaluation)	60
Fig. IV.9 Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble de test)	61
Fig IV.10 : Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble d'évaluation).....	62
Fig. IV.11 Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble de test).....	63
Fig.IV.12 Les courbes du TEE pour la PCA et la KPCA en fonction N_p [Haf 11].....	64

Liste d'abréviation

AAM: Active Appearance Model (Modèles Actifs d'Apparence)

ACL : Analyse des Caractéristiques Locales

ACP : Analyse en Composantes Principales

ADN : Acide DésoxyriboNucléique

AFIS : Automatic Fingerprint Identification System

ANN: Artificial Neural Network.

BDD : base des données

BIC:Les approches Bayésiennes

CAH: Classification Ascendante Hiérarchique

CMOS : Complementary Metal-Oxide Semiconductor

DLA: Dynamic Link Architecture

EBGM : Elastic Banch Graph Matching (Fr : Elastic Graph Matching Bunch)

EEG : Electro Encéphalo Gramme

EER: Equal Error Rate

EGM: Elastic Graph Matching (Appariement de graphes élastique)

FA : Fausse Acceptation (False Acceptance)

FR : Faux Rejet (False Rejection)

FAR: False acceptance Rate.

FRR: False Rejection Rate

FFT: Fast Fourier Transform

GMM: Gaussian Mixture Models

HMM: Hidden Markov Model (Modèle de Markov caché)

ICA : Independent Component Analysis (Analyse en composantes indépendantes)

ICP : Iterative Closest Point

ISO : International Standards Organization

IBG :International Biometric Group

JPEG : Joint Photographic Expert Group

Liste d'abréviation

KPCA : kernel principal composant analysis

LBP : Local Binary Pattern

LDA: Linear Discriminate Analysis (Analyse Discriminante Linéaire)

LFA : Local Feature Analysis (Analyse de Caractéristique Locale)

LG-PCA :Log Gabor PCA

NIST: National Institut of Standards and Technology

PCA : Principal Component Analysis

RDF : Reconnaissance Des Formes

RNA : Réseaux de Neurones Artificiels

SRV :Système de Reconnaissance de Visage

SV: Support Vector (vecteur de support)

SVM : Support Vector Machines (machine à vecteurs de support)

TER : Total Error Rate

TFD: Transformée de Fourier Discrète

TR : Taux de Reconnaissance

TFA : Taux de fausse acceptation

TFR : Taux de faux rejet

Résumé :


La reconnaissance de visage est une technologie biométrique en vogue, elle est très utilisée dans les applications de contrôle d'accès. Dans la littérature, on trouve plusieurs méthodes globales, locales et hybrides de reconnaissance de visages. Le but de ce projet est d'établir une étude comparative entre deux approches monomodales l'une basée sur l'Analyse en Composantes Principales (ACP) et la deuxième est une ACP à laquelle on associe un noyau (Kernel) pour mieux assurer la classification non linéaire. L'approche est basée sur un filtrage de Gabor dont les paramètres sont prise en considération dans l'amélioration des performances du système de reconnaissance de visages. Nous utilisons un classifieur à machines de vecteurs supports qui donne des résultats satisfaisants. Et l'étude comparative est menée entre une approche (PCA) et une approche KPCA associées à deux types de classifieurs SVM et mesures de distances. Le système de reconnaissance de visage à base de KPCA et SVM est réalisé sur la base de donnée XM2VTS et nous pouvons dire que le noyau PCA sur cette base donne de bons résultats surtout avec l'utilisation de filtre Gabor.

Mots clés : KPCA, PCA, Similarité, XM2VTS, filtre Gabor et SVM.

ملخص :

التعرف على الوجه هو التكنولوجيا الحيوية رائجة، ويستخدم على نطاق واسع في تطبيقات التحكم في الوصول الى النتائج، وهناك طرق عدة العالمية والمحلية والهجين التعرف على الوجه. والهدف من هذا المشروع هو وضع دراسة مقارنة بيننهجين مشروط أحادية، واحدة على أساس تحليل المكون الرئيسي (PCA)، والثاني هو التحليل الشامل الذي يقترن نواة (لضمان أفضل غير الخطية تصنيف. ويستند هذا النهج على مرشح Gabor الذي يعتبر المعلم في تحسين أداء نظام التعرف على الوجه. نستخدم المصنف من آلة ناقلات الدعم الذي يعطي نتائج مرضية. وأجريت دراسة مقارنة بين نهج (PCA) و KPCA المرتبطة نوعين من المصنفات SVM وقياسات المسافة. يتم تنفيذ نظام التعرف على الوجه وعلى أساس KPCA و SVM على قاعدة بيانات XM2VTS ويمكن القول إن نواة على هذا الأساس يعطي نتائج جيدة خصوص مع استخدام مرشح Gabor.

كلمات البحث : KPCA، PCA، تشابه، XM2VTS، والمرشحات، وجابور. SVM.



SOMMAIRE

Introduction générale.....	1
Chapitre I.....	3
I.1.Introduction	4
I.2. Reconnaissance de visage.....	4
I.3.La prosopagnosie et le traitement des expressions faciales.....	5
I.3.1 Les causes de la prosopagnosie.....	5
I.3.2 Prise En Charge.....	6
I.4 La fonctionnement de la reconnaissance de visage	7
I.4.1 Acquisition	7
I.4.2 Détection de visage.....	8
I.4.3 Le prétraitement.....	8
I.4.4 Extraction.....	9
I.4.5 Classification	9
I.4.6 Apprentissage.....	9
I.4.7 Décision	10
I.5 Avantages et inconvénients de la RV.....	11
I.6 Techniques de la reconnaissance de visages.....	11
I.6.1 Les méthodes Locales.....	12
I.6.2 Les méthodes globales.....	13
I.6.3 Les méthodes hybrides.....	14
I.7 Authentification et Identification.....	15
I.7.1 L'Identification.....	15.
I.7.2 L'authentification.....	16
I.8 Conclusion	16


Chapitre II	17
II.1 Introduction.....	18
II.2 Les méthodes de la classification.....	18
II.2.1 Décision Bayésienne.....	18
II.2.2 Réseaux de neurones.....	19
II.2.3 HMM (Hidden Markov Models).....	20
II.2.4 Machine à Vecteurs de Support (SVM).....	20
II.3 Analyse en Composantes Principales (PCA).....	20
II.3.1 Introduction.....	20
II.3.2 Principe de la PCA.....	22
II.4 Etude des méthodes globales a noyau.....	24
II.4.1 L'Analyse en Composantes Indépendantes linéaire et non linéaire.....	24
II.4.1.1 Analyse en Composantes Indépendantes ICA.....	24
II.4.1.2 Kernel ICA.....	25
II.4.2 L'analyse Discriminatoire Linéaire et Non Linéaire.....	26
II.4.2.1 LDA.....	26
II.4.2.2 KLDA.....	28
II.4.3 KPCA.....	30
II.5 Conclusion.....	30
Chapitre III	31
III.1 Introduction.....	32
III.2 Architecture du modèle conçu.....	32
III.2.1 Etape 1 : Prétraitement de visage.....	33
III.2.1.1 conversion Couleur (NG).....	33
III.2.1.2 Découpage.....	34

III.2.1.3 Filtrage de gabor.....	34
III.2.2 Etape 2 : Analyse par les ondelettes de Gabor.....	34
III.2.2.1 L'orientation de l'ondelette (θ)	35.
III.2.2.2 La fréquence centrale de l'ondelette (λ)	35.
III.2.2.3 La phase de la sinusoïde (φ)	36
III.2.2.4 Le support temporel de l'ondelette (σ)	36
III.2.2.5 L'enveloppe de la gaussienne (γ)	37
III.2.3 .Etape 3: KPCA: La réduction d'espace par KPCA	38
III.2.4 Etape 4 : SVM (machine à vecteur de support).....	40
III.3 CONCLUSION.....	43
Chapitre IV	44
IV.1 Introduction.....	45
IV.2 La base de données XM2VTS	45
IV.3 Environnement de programmation.....	46
IV.3.1 Implémentation du Programme.....	46
IV.3.2 Modules du programme	46
IV.3.2.1 Module 1 : Prétraitement et détection.....	46
IV.3.2.2 Module 2 :Extraction de paramètres	46
IV.3.2.3 Module 3 : Classification.....	47
IV.4 Architecture d'un système de reconnaissance de visage	47
IV.4.1. Organigramme d'apprentissage.....	47
IV.4.2. Organigramme de test.....	48
IV.5 Modules du système.....	50
IV.5.1 Module de prétraitement	50
IV.5.1.1 Conversion couleur NG et découpage d'une image	50

IV.5.1.2 Filtrage de l'image.....	51
IV.5.2 Extraction de paramètres	53
IV.5.2.1 Schéma fonctionnel de la KPCA	53
IV.5.2.2 L'algorithme de KPCA	54
IV.5.3 La classification	55
IV.5.3.1 Mesures de similarités.....	55
IV.5.3.2 Algorithme de calcul de TFA, TFR et seuillage	56
IV.5.3.3 SVM (Apprentissage)	57
IV.5.3.4 SVM (Vérification).....	57
IV.6 Résultats Expérimentaux	58
IV.6.1 Applications dans la base d'évaluation	58
IV.6.1.1 Application de KPCA dans la BDD évaluation avec le filtre Gabor	58
IV.6.1.2 Taux de reconnaissance dans l'ensemble d'évaluation et l'ensemble ...	59
VI.6.3 Comparaison du taux de reconnaissance pour différentes σ et différents N_p dans l'ensemble d'évaluation	60
IV.6.4 Comparaison du taux de reconnaissance pour différentes σ et différents N_p	61
VI.7 Etude comparative.....	63
IV.7.1 Comparaison entre PCA et KPCA.....	63
IV.7.2 Comparaison entre le KPCA et la PCA avec différents de classification.....	65
IV.7.3 Pour les résultats de KPCA	66
IV.8 Conclusion.....	66
Conclusion générale	68

BILBIOGRAPHIE

ANNEXE



***INTRODUCTION
GENERALE***

Introduction générale

Le but de la reconnaissance du visage est d'édifier des systèmes informatiques capables d'égaliser les être humains. La difficulté de la reconnaissance du visage par ordinateur varie énormément suivant les conditions d'acquisition.

Dans un environnement contrôlé, des paramètres tels que l'arrière plan, la direction et l'intensité des sources lumineuses, l'angle de la prise de vue, la distance de la caméra par rapport au sujet, sont des paramètres maîtrisables par le système. Dans un environnement non contrôlé, une série de prétraitements sont souvent indispensables avant d'effectuer la reconnaissance proprement dite. Il faut tout d'abord détecter la présence ou l'absence de visage dans l'image. Le visage doit ensuite être segmenté. Enfin, si nous travaillons sur un flux vidéo, le système doit suivre le visage d'une image à l'autre.

Notre sujet concerne donc l'exploitation d'informations capturées par des appareils adéquats afin de reconnaître des personnes par leurs visages. Notre étude a des applications et des implications financières et technologiques.

Plusieurs questions se posent à ce niveau : Que définit-on par les deux mots reconnaissance de visage en biométrie? Quelles sont les méthodes utilisées? Quelles sont les avantages et les inconvénients de la modalité visage en reconnaissance biométrique? Que représente la méthode utilisée dans notre approche la **KPCA** (Kernel Principle Component Analysis : Analyse en composantes principales à noyau) et quel est le principe du **SVM** (Support Vector Machine : machine à supports de vecteurs)? Et comment associe-t-on ces deux méthodes dans le but de la reconnaissance de visage? Les réponses à ces questions sont abordées dans les divers chapitres de notre mémoire.

Nous présentons un système de reconnaissance faciale bidimensionnelle, nous préconisons d'implémenter une technique pour l'extraction de caractéristiques pour l'analyse biométrique bidimensionnelle du visage. Pour cela nous adoptons deux méthodes statistiques bien connues de la reconnaissance faciale bidimensionnelle, **KPCA** comme un modèle d'entrée à un algorithme encore plus élaboré qui est machine à vecteur de support ou **SVM**. Cela réduit grandement les tailles des images, maintient un temps de calcul raisonnable et une discrimination efficace.

Introduction générale

Notre approche est caractérisée par **trois phases** fondamentales :

- i) **Phase de prétraitement** dans laquelle l'image est découpée, décimée, convertie en NG.
- ii) **Phase d'extraction de caractéristiques** et réduction d'espace ; dans laquelle l'image est filtrée par le filtre de **Gabor** puis transformée par **PCA** et **KPCA** pour être projetée dans les espaces respectifs pour obtenir les vecteurs descripteurs.
- iii) **Phase de classification** ; des mesures métriques sont réalisées et les scores obtenus sont soumis à **SVM** en vue d'être classés. Finalement une décision est prise et l'identification de la personne proclamée est assurée.

Notre mémoire se présente sous **quatre chapitres** comme suit :

Dans le **premier chapitre** nous définissons la reconnaissance de visage et nous présentons les différentes techniques utilisées.

Le **deuxième chapitre** est consacré à l'étude des méthodes de transformations globales la **PCA** et **KPCA**.

Notre modèle ainsi étudié et conçu est détaillé dans le **troisième chapitre**. Il se présente en trois phases principales : phase de prétraitement, phase d'extraction de paramètres (basé sur la **KPCA**) et la phase d'identification (**SVM**).

L'implémentation réalisée et les résultats obtenus se trouvent dans le **quatrième chapitre**.

Nous nous basons sur les travaux et résultats 2010[**Ben 10**] et 2011 [**HAF 11**] pour faire notre étude comparative.

Finalement, nous terminons notre mémoire par une conclusion et des perspectives envisagés.

CHI:

Systeme de reconnaissance de
visage

I.1.Introduction

De nos jours, ils existent des ordinateurs capables d'effectuer des tâches, qui faites par l'homme, demandent de l'intelligence. Malgré tout ce progrès, la machine est toujours située à des années lumières du cerveau humain si comparaison a lieu entre les deux, ceci est dû principalement à la complexité des tâches que nous cherchons à automatiser et à notre méconnaissance de cet organe mystérieux qu'est le cerveau et des mécanismes qui régissent son activité (l'activité cérébrale)[Moh 02].

Plusieurs méthodes de reconnaissance de visages ont été proposées ces dernières années, suivant deux grands axes: la reconnaissance à partir d'images fixes et la reconnaissance à partir de séquence d'images (vidéo)[Jou 06].

S'investir dans le domaine de la reconnaissance de visages est sans doute motivé par la multiplicité et la variété des champs d'application (haute sécurité, télésurveillance et contrôle d'accès...). Les travaux portant sur ce domaine, sous différentes conditions d'éclairage, d'expressions faciales et d'orientations, peuvent être répertoriés en deux catégories distinctes suivant qu'elles se rapportent à une approche géométrique ou une approche globale [Moa].

I.2 Reconnaissance de visage

La recherche en reconnaissance automatique des visages remonte au moins jusqu'aux années 1960. Cependant, les techniques les plus courantes remontent seulement à l'œuvre basée sur l'apparence à la fin des années 1980 et 1990 [Bru]. Cependant, il serait judicieux de s'intéresser à ces facteurs avant de mesurer la performance d'un système de reconnaissance: [Adj 07]

- L'environnement au moment de l'acquisition.
- Les différentes positions des capteurs.
- La qualité des capteurs.
- La mauvaise interaction entre l'utilisateur et les capteurs.

Appuyé par une deuxième place dans l'industrie de la biométrie avec une part de 19% du marché derrière l'empreinte digitale, la reconnaissance du visage s'avère le bon compromis entre le coût et la précision.

Le graphe suivant montre une comparaison des techniques biométriques les plus utilisées en fonction des coûts et de la précision [Adj 07] :



Fig. I.1 : Comparaison entre les différentes biométries existantes, par rapport à leur coût et précision

Le problème de cette méthode vient des possibles perturbations pouvant transformer le visage (maquillage, faible luminosité, présence d'une barbe ou d'une lunette, expression faciale inhabituelle (état émotionnelle), changement avec l'âge, etc.) [HAM 09].

I.3 La prosopagnosie et le traitement des expressions faciales

Un certain nombre de patients prosopagnosies peuvent traiter correctement les expressions faciales, ce qui souligne une nouvelle fois la spécificité des traitements visuels effectués sur les visages, qui peuvent être altérés sans que la perception des expressions ne le soit. De nombreux auteurs postulent donc l'existence d'une double voie de traitement contenant d'une part l'identité des visages et d'autre part les expressions (Bruce & Young, 1986 ; Haxby, Hoffman, & Gobbini, 2000). Une revue récente discute cependant ces modèles et propose un modèle alternatif dont le mérite doit maintenant être évalué (Calder & Young, 2005) [Bar 08].

I.3.1. Les causes de la prosopagnosie

La nature exacte de la prosopagnosie est largement discutée. Un point de vue dominant est que les visages sont des stimuli spéciaux car ils nécessitent un traitement configuratif spécifique. Cette hypothèse est principalement supportée par l'effet d'inversion des visages. Bien qu'un visage inversé à 180° ait presque les mêmes caractéristiques physiques qu'un visage à l'endroit, les sujets contrôles sont plus rapides et meilleurs pour traiter les visages à l'endroit qu'à l'envers. Cet effet est moins important pour les objets que

pour les visages, démontrant la spécificité de ce traitement pour les visages. Certains patients prosopagnosie ne montrent pas d'effet de l'inversion (Farah, Wilson, Drain, & Tanaka, 1995). Certains patients chez qui on évalue spécifiquement les capacités à traiter la configuration de deuxième ordre sont ainsi très déficitaires à ce type de tâche (Barton, Press, Keenan, & O'Connor, 2002 ; Joubert et al., 2003). Une autre hypothèse ancienne qui a récemment repris de l'importance est que la prosopagnosie est provoquée par un déficit spécifique du traitement de la région des yeux (la région de « l'ocula », Bodamer, 1947 ; Caldara et al, 2005). D'autres auteurs ont insisté sur l'importance du traitement des courbes pour reconnaître un visage (Kosslyn, Hamilton, & Bernstein, 1995 mais voir Barton, Cherkasova, Press, Intriligator, & O'Connor, 2004). La prosopagnosie pourrait être provoquée par l'altération de différents mécanismes dont la spécificité pour les visages et l'indépendance respective restent à déterminer [Bar 08].



Fig.I.2 : L'effet Thatcher (d'après Thompson, 1980 qui avait utilisé une photographie de Margaret Thatcher dans son exemple initial).

I.3.2.Prise En Charge

La sévérité de la prosopagnosie décroît généralement dans les quelques mois suivant les lésions. Il est difficile, voire impossible, de réentraîner le patient à la perception des visages. Il est par contre possible de lui proposer des stratégies alternatives basées sur la reconnaissance de détails caractéristiques par exemple [Bar 08].

I.4.Le fonctionnement de la reconnaissance de visage




Fig.I.3:Schéma de vérification d'un visage




Fig.I.4: Système de reconnaissance de visage

I.4.1 Acquisition

Un système d'acquisition équipé d'un capteur est utilisé pour acquérir une caractéristique spécifique de l'utilisateur, par exemple: un microphone dans le cas de la voix. [Fed 07]. C'est l'opération qui permet d'extraire du monde réel une représentation bidimensionnelle pour des objets en 3D, cette opération peut être statique (Appareil photo, Scanner, etc.) ou dynamique (Caméra, Web Cam), dans ce cas on aura une séquence vidéo .A ce niveau on aura une image brute [Bed 08] [Oua 09].




Fig.I.5: Exemple d'acquisition d'une image.

I.4.2. Détection de visage

L'efficacité des systèmes biométriques basés sur l'authentification de visage dépend essentiellement de la méthode utilisée pour localiser le visage dans l'image. Dans la littérature scientifique, le problème de localisation de visages est aussi désigné par la terminologie "détection de visages". Plusieurs travaux de recherches ont été effectués dans ce domaine. Ils ont donné lieu au développement d'une multitude de techniques allant de la simple détection du visage, à la localisation précise des régions caractéristiques du visage, tels que les yeux, le nez, les narines, les sourcils, la bouche, les lèvres, les oreilles, etc [Oli 08],[Benz 10],[Ais 11].




Fig.I.6 : Détection de visage

I.4.3 Le prétraitement

Où les données biométriques sont traitées pour enlever le bruit lié à l'environnement ou au dispositif de capture [Ben 10]. Il faut éliminer le bruit par des techniques de traitement et de restauration d'images et procéder à une détection de visages, cette opération est très complexe, surtout dans le cas où l'image contient plusieurs visages ou le cas où l'arrière plan n'est pas neutre [Oua 09].

Les performances globales de tout système automatique de reconnaissance dépendent amplement des performances de la détection de visages [Oli 08].

On peut diviser les approches de détection en quatre catégories : les méthodes basées sur la connaissance où on code la connaissance humaine du visage, les méthodes de correspondance de masques, les méthodes à caractéristiques invariables où on utilise la couleur, les textures et les contours, et finalement les méthodes les plus répandues et qui sont ceux basées sur l'apprentissage ou les statistiques comme **PCA**, **SVM** et Graph matching [Bel 94][Oua 09].

I.4.4 Extraction

Appelée aussi indexation, représentation, modélisation [Xié 04]. Ayant une image ou une voix en entrée, une étape de segmentation permet d'extraire la caractéristique dont le processus d'authentification a besoin. Par exemple: extraire le visage du fond d'une image dans le cas de l'identification de visage [Fed 07].

Pour extraire l'information utile contenue dans le signal capturé [Adj 07].

Le choix de ces informations utiles revient à établir un modèle pour le visage, elles doivent être discriminantes et non redondantes [Oua 09].

I.4.5. Classification

En examinant les modèles stockés dans la base de données, le système collecte un certain nombre de modèles qui ressemblent le plus à celui de la personne à identifier, et constitue une liste limitée de candidats. Cette classification intervient uniquement dans le cas d'identification car l'authentification ne retient qu'un seul modèle (celui de la personne proclamée) [Sid 11].

I.4.6. Apprentissage

D'une manière générale, nous posons le problème comme celui de l'apprentissage d'une distance entre visages. Nous supposons disposer d'un ensemble de paires d'images de visages, certaines de ces paires représentant des visages de personnes différentes, d'autres des paires de visages provenant de la même personne mais avec des variations d'expression, de pose ou d'illumination. Pour chacune de ces paires nous connaissons la vérité terrain, c'est-à-dire que nous savons s'il s'agit de la même personne ou non.

Notre calcul de similarité s'appuie sur quatre grandes étapes :

1. Chaque visage est représenté par un vecteur d'attributs.
2. Nous effectuons ensuite une transformation linéaire des données de départ en utilisant une méthode inspirée de [Lor 07], dont l'intérêt est, en plus de réduire la dimensionnalité, de calculer un espace de représentation qui sépare au mieux les données positives des négatives (paires de visages identiques ou différents).
3. Une phase d'apprentissage semi supervisé, où les données de test (dont les labels ne sont pas connus) sont utilisées pour déterminer avec plus de précision la structure des données dans l'espace de représentation. Cette phase repose sur la construction d'un

graphe où les nœuds représentent les paires de visages et les arêtes les relations entre ces paires.

4. L'apprentissage d'un classifieur qui combine les informations extraites à partir des deux méthodes précédentes pour mesurer la similarité de deux visages inconnus [Ale]. Elle consiste à mémoriser les représentations calculées dans la phase analyse pour les individus connus. Généralement les deux étapes d'analyse et d'apprentissage sont confondues et regroupées en une seule étape [Jou 06] .




Fig.I.7 : Exemple d'image d'apprentissage

I.4.7.Décision

Dans le cas de l'identification, il s'agit d'examiner les modèles retenus par un agent humain et donc décider. En ce qui concerne l'authentification, la stratégie de décision nous permet de choisir entre les deux alternatives suivantes: l'identité de l'utilisateur correspond à l'identité proclamée ou recherchée ou elle ne correspond pas [Rao 11] .

C'est dans ce module que le système donne sa réponse soit dans une identification par la personne de la base la plus proche, soit par une vérification (oui ou non)[Adj 07] .

Pour estimer la différence entre deux images, il faut introduire une mesure de similarité. Il est important de noter que le système de vérification automatique de visage se base en sa totalité sur la méthode de localisation [Bad 08] .

I.5 Avantages et inconvénients de la RV

Avantages	Inconvénients
<p>Bien accepté par le public.</p> <p>Aucune action de l'utilisateur (peu intrusive).</p> <p>Pas de contact physique.</p> <p>Technique peu coûteuse.</p>	<p>Technologie sensible à l'environnement (éclairage, position, expression du visage...)</p> <p>Difficultés de différencier de vrais jumeaux.</p> <p>Sensible aux changements.</p> <p>(barbe, moustache, lunettes, piercing, chirurgie...)</p>

Tab. I.1 Avantages et inconvénients de RV.

I.6 Techniques de la reconnaissance de visages

Les méthodes de reconnaissance de visage peuvent être séparées en trois grandes familles, les méthodes globales (ou holistiques), les méthodes locales et les méthodes hybrides:

I.6.1 Les méthodes locales

C'est une méthode géométrique [Yan 05], on l'appelle aussi la méthode à traits, à caractéristique locale, ou analytique [Jou 06]. Dans ces méthodes, le visage est représenté par un ensemble de vecteurs caractéristiques de dimensions faibles, plutôt que par un seul vecteur de grande dimension [Oli 08].

Les méthodes locales s'intéressent aux points critiques du visage comme le nez, la bouche, les yeux; ce qui va engendrer plus de détails. L'algorithme le plus connu dans ces approches est EBGM (Elastic Bunch Graph Matching). L'avantage de ces méthodes locales est qu'elles prennent en compte la particularité du visage en tant que forme naturelle à reconnaître et un nombre réduit de paramètres (de 9 à 14 distances au maximum à considérer) [Adj 07], en exploitant les résultats de la recherche en neuropsychologie et psychologie cognitive sur le système visuel humain [Oua 09].

La difficulté éprouvée c'est quand il s'agit de prendre en considération plusieurs vues du visage ainsi que le manque de précision dans la phase « extraction » des points qui constitue leur inconvénient majeur [Adj 07].

Leurs techniques sont : **BIC** (Les Approches Bayésiennes), **AAM** (Modèle Actif d'Apparence) **LBP** (Local Binary Pattern) **SVM** (Machines à Vecteur de Support).

I.6.2 Les méthodes globales

Les méthodes globales sont basées sur des techniques d'analyse statistique bien connues. Il n'est pas nécessaire de repérer certains points caractéristiques du visage à part pour normaliser les images [Sci PR].

Le principe de cette approche est d'utiliser toute la surface du visage comme source d'information sans tenir compte des caractéristiques locales comme les yeux, la bouche,...etc.

Les algorithmes globaux s'appuient sur des propriétés statistiques bien connues et utilisent l'algèbre linéaire. Ils sont relativement rapides à mettre en œuvre, mais sont sensibles aux variations d'illumination, de pose et d'expression faciale [Adj07].

Le principe des méthodes globales est d'utiliser le visage au complet comme source d'information, et ce sans segmentation de ses parties. En effet une image en niveau de gris de taille 112 x 92 est représentée par un vecteur de taille 10304, les couleurs ne sont généralement pas utilisées dans ses méthodes ce qui simplifie un grand nombre d'opérations [Fed 07]. L'Approche connexionniste [BES 00]. L'inconvénient de cette approche est que l'apprentissage est long. A ce jour, il n'est pas clair comment de tels systèmes vont s'étendre à des problèmes plus larges, il faut prendre en compte un grand nombre d'individus.

L'Approche **ACP** (ou Les Visages Propres) [SHE 00] [VAL 94], son but est de capturer la variation dans une collection d'images de visages et d'utiliser cette information pour coder et comparer les visages (en termes mathématiques : trouver les vecteurs propres de la matrice de covariance de l'ensemble des images de visages). Le nombre possible de visages propres peut être approximé en utilisant seulement les meilleurs visages propres qui correspondent aux plus grandes valeurs propres [TUR 91][Rap][Ete 96]. Cette approche rencontre le problème du coût des calculs élevé et celui de la détermination du nombre de visages propres utiles [DAI 98].

L'Approche Stochastique : Dans [Rab][Sam 93][SAM 94] on avance que, quand les images frontales sont balayées de haut en bas il y a un ordre naturel dans lequel les caractéristiques apparaissent, et de ce fait peut être modélisé d'une manière pratique en utilisant un modèle

caché de Markov (**HMM** : Hidden Markov Model). Ce modèle rencontre les problèmes de prises de vue des images en entrée

L'approche statistique et l'approche probabiliste: cette approche repose essentiellement sur la théorie de décision pour résoudre les problèmes de classement et de classification, et pour cela on utilise généralement la classification fondée sur le théorème de Bayes. Yang et Ahuja [YANG 98] présente une méthode pour détecter des visages humains à partir d'images en couleur. Un modèle de la couleur de la peau humaine basé sur une analyse statistique multi variante est construit pour capturer les propriétés chromatiques, et dans [YANG 99] Yang, Ahuja et Kriegman présentent une méthode de probabilité pour détecter les visages humains qui utilisent un mélange d'analyseurs de facteur. Cette approche pose le problème de la complexité de calcul qui est très élevée. L'approche réseaux de neurones: Les réseaux de neurones artificiels ou **RNA** sont des assemblages fortement connectés d'unités de calcul. Chacune des unités de calcul est un neurone formel qui est, en soi, une formulation mathématique ou un modèle très simplifié d'un neurone biologique. Les **RNA** ont des capacités de mémorisation, de généralisation et d'une certaine forme d'apprentissage. On classe généralement les réseaux de neurones en deux catégories: les réseaux faiblement connectés à couches que l'on appelle des réseaux «feed for ward » ou réseaux directs et les réseaux fortement connectés que l'on appelle des réseaux récurrents. Dans ces deux configurations, on retrouve des connexions totales ou partielles entre les couches. Les réseaux de neurones peuvent être utilisés tant pour la classification, la compression de données ou dans le contrôle de systèmes complexes en automatique. Cette approche repose essentiellement sur la notion d'apprentissage qui est depuis de nombreuses années au cœur des recherches en intelligence artificielle [Ric 04] .

L'idée est d'identifier à partir d'exemples un visage (ici une personne) De manière plus formelle, l'apprentissage du réseau a pour but l'extraction des informations pertinentes [pal] à l'identification. [Moa]

L'avantage principal des méthodes globales est qu'elles sont relativement rapides à mettre en œuvre et que les calculs de base sont d'une complexité moyenne [Sci PR]. En revanche, elles sont très sensibles aux variations d'éclairage, de pose et d'expression faciale. Ceci se comprend aisément puisque la moindre variation des conditions de l'environnement ambiant entraîne des changements inéluctables dans les valeurs des pixels qui sont traités directement.

Par exemple, considérons une petite image de 64×64 , en niveaux de gris codés sur 8 bits (donc de 0 à 255). Cette dernière possède 4096 pixels qui peuvent exprimer un grand nombre de classes de formes, comme des arbres, des maisons ou encore des visages.

Cependant, parmi les $256^{4096} > 109864$ "configurations" possibles, seulement une petite quantité peut correspondre à des visages. Ainsi, la représentation de l'image originale est très redondante et de cette représentation pourrait être grandement réduite si l'on se concentre uniquement sur les formes qui nous intéressent. L'utilisation de techniques de modélisation de sous-espace a fait avancer la technologie de reconnaissance faciale de manière significative [Bel].

L'inconvénient majeur des méthodes globales est l'insuffisance de l'information extraite représentant le visage, car ces méthodes ne prennent pas en considération les variations locales en essayant de concentrer le maximum d'énergie [Adj 07].

Nous pouvons distinguer deux types de techniques parmi les méthodes globales: **les techniques linéaires: PCA** (Analyse en Composante Principale), **LDA** (Analyse Discriminante Linéaire) et **ICA** (Analyse en Composante Indépendantes) et **les techniques non linéaires**. Afin de pouvoir traiter ce problème de non-linéarité en reconnaissance visage, de telles méthodes linéaires ont été étendues à des techniques non linéaires basées sur la notion mathématique de noyau (kernel) comme le **Kernel PCA** et le **Kernel LDA**. Ici, une projection non linéaire (réduction de dimension) de l'espace de l'image sur l'espace de caractéristiques (feature space) est effectuée; les variétés présentes dans l'espace de caractéristiques résultant deviennent simples, de même que les subtilités des variétés qui sont préservées [Bel].

I.6.3 Les méthodes hybrides

Elle se présente comme une association des avantages entre les méthodes globales et locales [AIS 11]. Elles permettent d'augmenter la stabilité de la performance de reconnaissance lors de changements de pose, d'éclairage et d'expressions faciales [Haf 11]. Elles se basent sur le fait que le système de perception humain emploie les caractéristiques locales et la région entière du visage pour l'identification [Oua 11].

Les techniques permises de cette méthode sont: **LFA** (Analyse de Caractéristique Locale), **EGM** (Elastic Graph Matching), **EBGM** (Elastic Buch Graph Matching) et **LG-PCA** (Log Gabor PCA).




Fig.I.8 : Les méthodes de la reconnaissance de visage.

I.7 Authentification et Identification

I.7.1 L'identification

C'est un procédé permettant de déterminer l'identité d'une personne. Il ne comprend qu'une étape. L'utilisateur fournit un échantillon biométrique qui va être comparé à tous les échantillons biométriques contenus dans la base de données biométriques du système. Si l'échantillon correspond à celui d'une personne de la base, on renvoie son numéro d'utilisateur sinon l'identification échoue [Oua 11] .

Pour évaluer les performances d'un système d'identification, on calcule le taux de reconnaissance du système. On effectue n fois le test et on voit, si la réponse du système (la personne la plus proche résultante de la comparaison entre le test et la base d'apprentissage) [Adj 07] .




Fig.I.9 : Reconnaissance et identification dépendant des paramètres de points de vue

I.7.2 L'authentification

La reconnaissance automatique de visages est la technique d'authentification biométrique la plus naturelle et la plus prometteuse. Cependant, alors qu'un humain semble capable de reconnaître une personne à l'aide d'une simple photo, ceci semble hors d'atteinte pour un ordinateur. Les nouvelles méthodes s'orientent donc vers une modélisation 3D du visage pour prendre en compte ses propriétés élastiques caractéristiques [Suj 12].

C'est un procédé permettant de vérifier l'identité d'une personne. Il comprend deux étapes:

- L'utilisateur fournit un identifiant au système de reconnaissance (par exemple un numéro d'utilisateur)
- 2. L'utilisateur fournit ensuite un échantillon biométrique qui va être comparé à l'échantillon biométrique correspondant à l'utilisateur « Id » contenu dans la base de données biométrique du système. Si la comparaison correspond, l'utilisateur est authentifié [Oua 09].




Fig. I.10 : La reconnaissance automatique de visages est la technique d'authentification biométrique

I.8 Conclusion

À travers ce chapitre, nous avons présenté un résumé de l'état de l'art des techniques de reconnaissance de visages. Nous avons vu que chaque technique possède ses avantages et ses inconvénients, ce qui a entraîné l'apparition de l'approche de combinaison de méthodes et de biométries pour profiter des complémentarités qui existent entre elles. La reconnaissance de visages est une technologie biométrique qui est trop utilisée dans les applications de contrôle de frontières, dans la sécurité des établissements et des zones urbaines et dans l'identification des conducteurs. C'est une technique commune, populaire, simple et qui offre beaucoup d'avantages. Dans le chapitre suivant nous enchaînerons avec l'étude de la **KPCA** qui est à la base de notre système conçu.

CH II :

Méthodes globales et étude de
la PCA et KPCA

II.1.Introduction

La reconnaissance faciale est une tâche que les humains effectuent naturellement et sans effort dans leurs vies quotidiennes. La grande disponibilité d'ordinateurs puissants et peu onéreux ainsi que des systèmes informatiques embarqués ont suscité un énorme intérêt dans le traitement automatique des images et des vidéos numériques au sein de nombreuses applications, incluant l'identification biométrique, la surveillance, l'interaction homme-machine et la gestion de données multimédia.

La reconnaissance du visage (RV) peut être utilisée sans contact direct. Elle peut être utilisée n'importe où et employée dans diverses applications. Cependant, elle souffre de divers changements de la même face et la grande taille de l'image. Depuis deux décennies, diverses méthodes RV ont été proposées pour réduire la quantité de calcul et d'améliorer le taux reconnaissance.

L'utilisation de techniques de reconnaissance faciale a connu un développement à grande échelle, avec l'utilisation efficace de nouvelles technologies, notamment l'ordinateur et sa capacité de traitement d'images et de fouille de données (*datamining*); ce qui lui a donné de nouvelles applications [Atia2011].

II.2.Les méthodes de la classification

Plusieurs travaux ont été menés au cours de la dernière décennie sur la catégorisation de textes : les classificateurs Bayésiens, réseaux de neurones, **HMM** et **SVM**. D'autres approches adoptées utilisaient des systèmes experts comme le système construit développé par Carnegie Group.

II.2.1.Décision Bayésienne

Dans une approche par modélisation, on cherche un modèle de production $\mathbf{p}(\mathbf{x}/c_i)$, qui donne pour chaque classe de formes c_i , la distribution des données qui lui sont associées.

Dans une approche par discrimination, on cherche à approximer la distribution $\mathbf{p}(c_i/\mathbf{x})$ qui représente la probabilité à posteriori des données étant donné la classe c_i . En pratique, cette information n'est pas toujours fournie.

La règle de décision bayésienne est une théorie clé en classification qui permet d'estimer la probabilité à posteriori à partir de la probabilité conditionnelle et d'émettre un vote d'appartenance de la forme traitée. Elle s'écrit :

$$p\left(\frac{c_i}{x}\right) = \frac{p\left(\frac{x}{c_i}\right)p(c_i)}{p(x)} \quad (\text{Equ.II.1})$$

Pour \mathbf{K} classes, la décision bayésienne cherche la classe c_i qui maximise la probabilité à posteriori. Elle s'écrit :

$$c(x) = \arg \max p\left(\frac{c_i}{x}\right) \quad (\text{Equ.II.2})$$

Le terme $p(c_i)$ représente la probabilité a priori de la classe c_i . Il est particulièrement utiles si les classes ne sont pas balancées dans l'échantillon de données considéré. La vraisemblance de l'observation $p(x)$, est une quantité constante qui peut être omise du processus de décision [Nad 04].

II.2.2. Réseaux de neurones

Les réseaux de neurones récurrents ou bouclés sont par leur structure adaptés au traitement de données séquentielles. En particulier, la prévision de séries temporelles est une application indispensable dans de nombreux domaines tels que la météo, la finance ou le marketing. On continue la recherche d'améliorations à appliquer au problème de l'apprentissage des dépendances temporelles pour la prévision de valeurs futures. Une application en cours de développement est la reconnaissance de phonèmes à partir de séquences vidéo [Xie 04]. Les grands avantages des réseaux de neurones résident dans leur capacité d'apprentissage automatique, ce qui permet de résoudre des problèmes sans nécessiter l'écriture de règles complexes, tout en étant tolérant aux erreurs. Ils résident aussi dans leur capacité à prendre une décision à partir de critères non formalisables explicitement [Oua 10].

Les réseaux de neurones artificiels ou **RNA** sont des assemblages fortement connectés d'unités de calcul. Une image brute (ou prétraitée) de dimensions fixes constitue habituellement la source d'entrée des réseaux. Les dimensions doivent être établies au préalable car le nombre de neurones sur la couche d'entrée en dépend. Cela étant dit, plus les dimensions de l'image sont élevées, plus la complexité et le temps d'apprentissage augmentent. En effet, pour une image de dimensions 130×150 pixels, 19500 neurones seront

requis sur la couche d'entrée, ce qui est énorme. L'apprentissage efficace d'un tel réseau est également douteux.

Grâce à leur grande capacité d'apprentissage automatique à partir de données modélisant le problème à résoudre, les réseaux de neurones permettent de remplacer efficacement des modèles mathématiques pouvant être extrêmement complexes.

L'avantage de ce modèle est sa robustesse face aux variations d'inclinaison et changement d'échelle. Cependant, l'utilisation d'exemples pour apprendre, apporte le risque de ne pouvoir résoudre que des situations déjà rencontrées, c.à.d. un phénomène de sur-apprentissage qui spécialiserait le réseau uniquement sur les exemples connus sans généraliser.

II.2.3.HMM (Hidden Markov Models)

On avance que, quand les images frontales sont balayées de haut en bas il y a un ordre naturel dans lequel les caractéristiques apparaissent et de ce fait on peut les modéliser d'une manière pratique en utilisant un modèle caché de Markov (**HMM** : Hidden Markov Model). Ce modèle rencontre les problèmes de prises de vue des images en entrée et il est coûteux en temps de calcul.

II.2.4.Machine à Vecteurs de Support (SVM)

L'origine des machines à vecteurs de support (**SVM**) remonte à 1975 lorsque Vapnik et Chervonenkis proposèrent le principe du risque structurel et la dimension **VC** pour caractériser la capacité d'une machine d'apprentissage. A cette époque, ce principe n'a pas trouvé place et il n'existait pas encore un modèle de classification solidement appréhendé pour être utilisable. Il a fallu attendre jusqu'à l'an 1982 pour que Vapnik propose un premier classificateur basé sur la minimisation du risque structurel baptisé **SVM**.

SVM (Support Vector Machines) est une nouvelle technique d'apprentissage statistique, proposée par V. Vapnik en 1995. Elle permet d'aborder des problèmes très divers comme le classement, la régression, la fusion, etc.

II.3. Analyse en Composantes Principales (PCA)

II.3.1.Introduction

La **PCA** (Principal Component Analysis, Pearson, 1901) Sirovich et Kirby appliquée **PCA** pour la représentation efficace d'une image de visage pour la première fois. Ils représentaient une image de visage comme une addition d'un petit nombre de valeurs de poids

défini comme un vecteur de base du visage et du vecteur moyen. Ils ont fait valoir que toute image de visage pourrait être reconstruite à peu près comme une moyenne pondérée somme d'une petite collection d'images que définis base du visage et une image moyenne de la face. Turk et Pentland ont proposé une méthode visages propres pour la reconnaissance faciale en 1991. La **PCA** est une méthode linéaire qui a le but de trouver les axes maximisant la variance des données (minimisant l'écart au carré par rapport aux axes). Dans cette approche, l'image a deux dimensions d'un visage est transformée en un vecteur obtenu en enchaînant les lignes (ou colonnes) de l'image. La **PCA** est une extraction de caractéristiques et de la technique traditionnelle de représentation des données largement utilisées dans les domaines de la reconnaissance des formes, vision par ordinateur [You 08]. La **PCA** est une méthode linéaire très utilisée pour la réduction de dimension, pour la visualisation de données ainsi que pour la compression. Les vecteurs de base de la **PCA** sont calculés à partir d'un ensemble de formation d'images I une première étape, l'image moyenne est calculée dans I et soustrait du les images de formation, la création d'un ensemble d'échantillons de données On calcule les valeurs propres et vecteurs propres de la matrice de covariance produit à partir de la transformée en un vecteur unidimensionnel visage [You 08]. Une propriété importante de la **PCA** est qu'elle génère les caractéristiques qui rendent compte des directions de dispersion principaux et est donc optimale pour la représentation dans un réduit l'espace en termes de minimum d'erreur quadratique moyenne.

Donc, son idée principale est de chercher la plus précise des représentations (projections) dans un sous-espace de dimension inférieure.




Fig.II.1 Exemple de projection suivant **PCA**

II.3.2 Principe de la PCA

Les visages propres sont des images de la même taille que les images d'apprentissage et qui montrent des visages ayant un aspect fantomatique. Mathématiquement, elles sont les

composantes principales de la distribution des visages, ou les vecteurs propres de la matrice de covariance de l'ensemble des images de visage. Chaque image de visage de l'ensemble d'apprentissage peut être exactement représentée en termes de combinaison linéaire des visages propres et du visage moyen. La **PCA** est une technique rapide, simple et populaire dans l'identification de modèle, c'est l'une des meilleures techniques [Oua 09].

En terme mathématique, c'est de calculer les composantes principales d'une distribution de visages, par le calcul des vecteurs propres (**Eigen Face**) de la matrice de covariance de l'ensemble des visages et les ordonnées suivant les valeurs propres correspondantes.

Chaque vecteur propre suivant sa valeur propre-il capturera une grande ou petite variation des visages de la distribution étudiée et l'ensemble de ces vecteurs caractérisent les variations totales des images. Ainsi, ces vecteurs propres représenteront la base de projection des visages dans l'espace propre, soit dans l'apprentissage pour produire les modèles ou dans le test pour pouvoir classifier en comparant le modèle test avec ceux de la base d'entraînement.

On considère un vecteur \mathbf{X} représentant une distribution de n données de dimension \mathbf{p} (p variable explicatives) à partir d'un échantillon de \mathbf{K} réalisations conjointes de ces variables

$$\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2 \ \dots \ \mathbf{X}_i \ \dots \ \mathbf{X}_n] = \begin{bmatrix} X_{1,1} & \dots & X_{1,N} \\ \vdots & \ddots & \vdots \\ X_{K,1} & \dots & X_{K,N} \end{bmatrix} \quad (\text{Equ.II.3})$$

On désire représenter le plus exact possible cette distribution dans un espace \mathbf{E} de dimension \mathbf{k} ($k \leq p$) et tel qu'en sortie on aura les données indépendantes entre elles (matrice de covariance diagonale).

Soit $\mathbf{Y} = [\mathbf{Y}_1 \ \mathbf{Y}_2 \ \dots \ \mathbf{Y}_i]$ la projection de \mathbf{X} à travers \mathbf{W} la matrice de projection, dans le nouveau sous-espace, alors Le vecteur moyen de l'ensemble d'apprentissage est donné par :

$$\frac{1}{N} \sum_{i=1}^N X_i \quad (\text{Equ.II.4})$$

Ce vecteur est soustrait de chaque vectrice image. La vectrice image centré est donné par :

$$\overline{X}_i = X_i - \mu \quad (\text{Equ.II.5})$$

La transformation linéaire d'une image original est donnée par :

$$Y_i = W^T \overline{X}_i \quad (\text{Equ.II.6})$$

Les vecteurs de base de transformation en utilisant la **PCA** sont définies par les vecteurs propres de la matrice de covariance S_T donnée par :

$$S_T = \frac{1}{N} \sum_{i=1}^N (X_i - \mu)(X_i - \mu)^T \quad (\text{Equ.II.7})$$

La **PCA** d'une matrice de données met en facteurs sa matrice covariance dans la forme suivante:

$$S_T = \Phi \Lambda \Phi^T, \Phi = [\phi_1 \phi_2 \dots \phi_i \dots \phi_n], \quad (\text{Equ.II.8})$$

$$\Lambda = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_n\}$$

La matrice W_{PCA} de transformation se compose de vecteurs propres correspondant aux d plus grandes valeurs propres.

Néanmoins, la **PCA** ne nécessite aucune connaissance a priori sur l'image; le principe selon lequel on peut construire un sous-espace vectoriel en ne retenant que les meilleurs vecteurs propres, tout en conservant beaucoup d'information utile non redondante, fait de **PCA** un algorithme efficace et couramment utilisé en réduction de dimensionnalité et reconnaissance de formes où il peut alors être utilisé en fusion avec d'autres algorithmes (comme la LDA par exemple). L'algorithme **PCA** est né des travaux de **MA Turk** et **MP Pentland**, en 1991. Il est aussi connu sous le nom d'Eigenfaces, car il utilise des vecteurs propres et des valeurs propres (respectivement Eigenvectors et Eigenvalues en anglais) ; C'est une méthode globale utilisant en premier lieu les niveaux de gris des pixels d'une image.



Fig.II.2 Exemple d'Eigen Faces. La rangée du haut contient les huit vecteurs propres avec les plus hautes valeurs propres pour l'ACP

II.4. Etude des méthodes globales à noyaux

Les méthodes basées noyau s'explique par un cadre intégration de graphes sont analysées et leur nature est révélé, c'est à dire tout noyau-base méthode dans une intégration de graphes cadre est équivalent à une analyse en composantes du noyau principal et de son correspondant linéaire, basé sur ce résultat, les auteurs proposent un noyau complet basé sur

des algorithmes cadre. Tout algorithme dans notre cadre permet d'utiliser pleinement les deux types de discriminant l'information, régulière et irrégulière [Gui-Fu 11] .

Réduction de la dimension a été un problème majeur dans de nombreux domaines de traitement de l'information, tels que l'apprentissage machine, l'exploration de données, récupération de l'information, et la reconnaissance des formes.

L'hypothèse du sous-espace linéaire dans les méthodes mentionnées ci-dessus est limitée dans de nombreuses applications réelles comme la reconnaissance faciale. Comme montré dans, la variation apparence complexe causée par pose génère la non-linéarité. Astuce du noyau est une approche couramment utilisée pour traiter les de manière non linéaire dans la structure de données. L'idée clé de méthodes du noyau est de cartographier les données originales à un espace caractéristique de dimension supérieure où les produits scalaires peuvent être calculés par un noyau fonction sans connaître la fonction de mappage non linéaire explicitement.

II.4.1 L'Analyse en Composantes Indépendantes linéaire et non linéaire

II.4.1.1 Analyse en Composantes Indépendantes ICA

Le but de l'ICA est d'extraire des caractéristiques qui sont indépendantes l'une de l'autre. Cette idée a beaucoup été utilisée dans le contexte de la séparation aveugle de source (BSS pour Blind Source Séparation) : si par exemple on enregistre les conversations se tenant dans une salle où plusieurs personnes parlent simultanément, le signal perçu est une combinaison linéaire de ces différentes conversations. Séparer ces conversations peut alors se faire en extrayant leurs signaux individuels, que l'on suppose indépendants entre eux. Une autre motivation pour l'extraction de caractéristiques indépendantes entre elles réside dans la supposition que dans le cerveau, le codage de l'information minimise la redondance (Barlow, 1989). Il existe de nombreux algorithmes d'ICA, qui diffèrent en particulier par le type de transformation apprise (par exemple linéaire ou non linéaire), ainsi que par le critère utilisé pour maximiser l'indépendance des caractéristiques extraites. Les plus importants parmi ces algorithmes sont décrits dans des articles de revue ou livres (Hyvärinen, 1999; Hyvärinen et al, 2001), et les plus récents développements sont accessibles en parcourant les articles publiés lors de l'International Conference on Independent Component Analysis and Signal Séparation.

II.4.1.2 Kernel ICA

Dans l'ICA à noyau de Bach et Jordan (2002), on utilise une forme de corrélation non Linéaire portée par un espace de Hilbert à noyau reproduisant (RKHS) F_{σ} .

L'espace F_σ est issu du noyau gaussien isotrope $k(x, y) = e^{-\frac{1}{2\sigma^2} \|x - y\|^2}$ avec $\phi = F_0$ et F_σ croît vers $L_2(\mathbb{R}^d)$ quand $\sigma^2 \rightarrow +\infty$

Le paramètre σ est donc l'équivalent du paramètre de résolution j dans l'ACI par ondelettes.

Soit W , inverse potentiel de la matrice A solution de $x = As$, soit $y_i = Wz_i$ où z_i est la transformation ACP de x_i , l'observation i .

On utilise l'estimateur

$$\widehat{cov F_\sigma}(y^1, y^2) = \frac{1}{n} t \alpha^1 k_1 k_2 \alpha^2 \quad (\text{Equ.II.9})$$

et

$$\widehat{pF}(y^1, y^2) = \max_{\alpha^1, \alpha^2} \frac{t \alpha^1 k_1 k_2 \alpha^2}{(t \alpha^1 k_1^2 \alpha^1)^{\frac{1}{2}} (t \alpha^2 k_2^2 \alpha^2)^{\frac{1}{2}}} \quad (\text{Equ.II.10})$$

Où K_1 et K_2 sont les matrices $n \times n$ de Gram données par

$$k_\ell = \begin{pmatrix} k(y_1^\ell, y_1^\ell) & \cdots & k(y_1^\ell, y_n^\ell) \\ \vdots & \ddots & \vdots \\ k(y_n^\ell, y_1^\ell) & \cdots & k(y_n^\ell, y_n^\ell) \end{pmatrix}$$

La solution de ce problème de corrélation canonique est donnée par la solution du problème de la valeur propre généralisée

$$\begin{pmatrix} 0 & k_1 k_2 \\ k_2 k_1 & 0 \end{pmatrix} \begin{pmatrix} \alpha^1 \\ \alpha^2 \end{pmatrix} = \rho \begin{pmatrix} k_1^2 & 0 \\ 0 & k_2^2 \end{pmatrix} \begin{pmatrix} \alpha^1 \\ \alpha^2 \end{pmatrix} \quad (\text{Equ.II.11})$$

Dans le cas général on forme une super matrice de Gram des K_ℓ , préalablement centres de dimension $(nd \times nd)$ notée [\[PAS 06\]](#)

$$k: k = (k_1 \dots k_d)(k_1 \dots k_d)'$$

II.4.2 L'analyse Discriminatoire Linéaire et Non Linéaire

II.4.2.1 LDA

L'analyse discriminante linéaire (**LDA**, Fisher, 1936, aussi McLachlan, 2004) cherche, pour un problème de classification binaire, la projection linéaire unidimensionnelle qui sépare le mieux les deux classes. L'algorithme peut être adapté pour un problème de classification à c classes de manière à obtenir une projection dans un espace à $c - 1$ dimensions (Bishop, 2006). Comme dans la **KPCA** (section 3.2.1), la **LDA** peut aussi être transformée en un

algorithme non linéaire en utilisant l'astuce du noyau (Baudat and Anouar, 2000). Sugiyama (2007) propose également une variante de **LDA** inspirée des **LPP** qui

- (i) permet de mieux gérer le cas où les classes sont multimodales, et
- (ii) autorise une projection des données dans un nombre arbitraire de dimensions (non limité par le nombre de classes c).

De ce fait, l'Analyse Discriminante Linéaire (**LDA** en anglais) est apparue (Fisher 1936), cette technique essaye de trouver la projection (la combinaison linéaire des variables explicatives observées sur les individus) qui maximise les variations interclasses et minimise les variations intra classe, donc c'est séparé les classes entre elles et regrouper les individus de la même classe, ce qui nous garantit une meilleure discrimination, comme le montre le résultat de cette méthode appliquée au même exemple de la figure II.3:




Fig.II.3 Projection par LDA avec séparation entre les classes

L'analyse discriminante linéaire (**LDA**) et les discriminants linéaires de Fisher (**FLD**) relatifs, sont utilisés pour trouver la combinaison linéaire des caractéristiques qui séparent le mieux les classes d'objet ou d'événement. Les combinaisons résultantes peuvent être employées comme **classificateur linéaire**, ou généralement dans la réduction de caractéristiques [Oua 11]. La **LDA** est étroitement liée à la **PCA**, du fait que toutes les deux recherchent des combinaisons linéaires des variables qui représentent au mieux les données. La **LDA** essaye explicitement de modéliser la différence entre les classes des données. La **PCA** quand à elle, ne tient pas compte des différences entre les classes.

Chaque visage, qui se compose d'un grand nombre de pixels, est réduit à un plus petit ensemble de combinaisons linéaires avant la classification.

Chacune des nouvelles dimensions est une combinaison linéaire des valeurs de pixels. Les combinaisons linéaires obtenues en utilisant **FLD** s'appellent les Fisher faces, en analogie avec les visages propres (Eigenfaces).

La **LDA** est une technique qui cherche les directions qui sont efficaces pour la discrimination entre les données. La figure II.4 représente un exemple de classification de deux nuages de

points. L'axe principal de la **LDA** est l'axe de projection qui maximise la séparation entre les deux classes. Il est clair que cette projection est optimale pour la séparation des deux classes par rapport à la projection sur l'axe principal calculé par **PCA**.




Fig.II.4 Comparaison entre les projections de deux classes de points (class1 et class2) sur les axes principaux construits par PCA et par LDA.

Tout comme dans le **PCA**, on rassemble les images de la base d'apprentissage dans une grande matrice d'images Γ où chaque colonne représente une image Γ_i , puis on calcule l'image moyenne Ψ [Nic 09].

Ensuite, pour chaque classe C_i , on calcule l'image moyenne Ψ_{C_i} :

$$\psi_{C_i} = \frac{1}{q_i} \sum_{k=1}^{q_i} \Gamma_k \quad (\text{Equ.II.14})$$

Avec θ_i , le nombre d'images dans la classe X_i .

Chaque image Γ_i de chaque classe X_i est ensuite recentrée par rapport à la moyenne.

On obtient alors une nouvelle image θ_i :

$$\Phi_i = \Gamma_i - \psi_{C_i} \quad (\text{Equ.II.15})$$

Vient ensuite le calcul de nos différentes matrices de dispersion. On notera X_i le nombre total de classes (i.e. le nombre d'individus), θ_i le nombre d'images dans la classe X_i et M le nombre total d'images.

1. La Matrice de Dispersion Intra-Classe (S_ω)

$$S_\omega = \sum_{i=1}^c \sum_{\Gamma_k \in C_i} (\Gamma_k - \Psi_{C_i})(\Gamma_k - \Psi_{C_i})^T \quad (\text{Equ.II.16})$$

2. La Matrice de Dispersion Inter-Classe (S_b)

$$S_b = \sum_{i=1}^c q_i (\Psi_{C_i} - \Psi)(\Psi_{C_i} - \Psi)^T \quad (\text{Equ.II.17})$$

3. La Matrice de Dispersion Totale S_T

$$S_T = \sum_{i=1}^M (\Gamma_i - \psi)(\Gamma_i - \psi)^T \quad (\text{Equ.II.18})$$

Une fois ces matrices calculées, nous devons trouver une projection optimale W qui minimise la dispersion intra-classe, relative à la matrice S_W , tout en maximisant la dispersion interclasse, relative à la matrice S_B [HAF 11].

- **Inconvénient**

FLD exige un grand nombre d'échantillons de l'ensemble d'apprentissage pour la bonne généralisation. Quand un tel besoin n'est pas répondu, la **FLD** crée un problème de sur-ajustement aux données d'apprentissage et ceci s'apprête mal aux nouvelles données de test [Oua 11].

II.4.2.2 KLDA

Supposons qu'on dispose d'un ensemble d'apprentissage constitué de n individus x_k , se répartissant en n_1 et n_2 représentants pour les deux classes en compétition $C1$ et $C2$. La méthode **KFD** consiste en la recherche d'une fonction ψ de H de sorte que la statistique $\lambda(x) = \langle \psi; \phi(x) \rangle_H$ maximise le critère de Fisher. En pratique, cette recherche est limitée au sous-espace H_n engendré par les n fonctions $\{\phi(x_k)\}_{1 \leq k \leq n}$, où les x_k désignent les éléments de la base d'apprentissage.

L'idée du discriminant de Fisher non-linéaire (de l'anglais «Kernel Fisher Discriminant») est de résoudre le discriminant de Fisher classique dans l'espace augmenté F induit avec un noyau de Mercer quelconque. La discrimination devient non-linéaire dans l'espace d'origine. Le discriminant de Fisher désigné par **LDA** (de l'anglais «Linear Discriminant Analysis») vise à trouver l'hyper-plan qui maximise la variance interclasse et minimise la variance intra-classe des données. Ceci est traduit par le critère de Rayleigh s'écrivant :

$$J(W) = \frac{W^T S_B W}{W^T S_W W} \quad \text{où } S_B = (m_2 - m_1)(m_2 - m_1)^T, \quad (\text{Equ.II.19})$$

S_B : représente la variance interclasse et

$$S_W = \sum_{k=1,2} \sum_{i \in I_k} (x_i - m_k)(x_i - m_k)^T, \quad (\text{Equ.II.20})$$

S_W : représente la variance intra-classe.

Ici, m_k et I_k sont respectivement la moyenne et l'ensemble des exemples de la classe k . Si les classes suivent deux distributions gaussiennes, le discriminant de Fisher est optimal au sens de Bayes. Le même constat peut être généralisé au cas multi classe.

De la même façon que pour le **SVM**, il est possible d'appliquer l'algorithme du **LDA** dans l'espace augmenté induit par un noyau de Mercer quelconque en utilisant une expansion de la forme :

$$w = \sum_{i=1}^l \alpha_i \phi(x_i), \quad (\text{Equ.II.21})$$

l étant le nombre total d'exemples.

En substituant l'équation II.21 dans l'équation II.19, nous trouvons le critère d'optimisation à maximiser suivant :

$$J(\alpha) = \frac{(\alpha^T \mu)^2}{\alpha^T N \alpha} = \frac{\alpha^T M \alpha}{\alpha^T N \alpha} \quad (\text{Equ.II.22})$$

Où

$$\begin{aligned} \mu_k &= \frac{1}{|I_k|} K \cdot \mathbf{1}_k, \\ N &= K \cdot K^T - \sum_{k=1,2} |I_k| \mu_k \mu_k^T, \\ \mu &= \mu_1 - \mu_2, \quad M = \mu \cdot \mu^T. \end{aligned}$$

K est la matrice dont les composantes K_{ij} sont égales à $\phi(x_i) \cdot \phi(x_j)$.

$|I_k|$ représente la taille de l'ensemble de données appartenant à la classe k .

La projection d'une donnée de test sur l'hyper-plan de séparation donne :

$$w \cdot \phi(x) = \sum_{i=1}^l \alpha_i k(x_i, x).$$

Dans le but de solutionner l'équation II.22, on résout le système propre donné par

$$M \alpha = \lambda N \alpha$$

donc la solution est

$$\alpha = N^{-1}(\mu_2 - \mu_1).$$

Toutefois, pour un grand ensemble de données, la solution est prohibitive en mémoire et en temps de calcul. Mika et al ont pu transformer la fonction objective $J(\alpha)$ en un problème de programmation linéaire convexe rendant possible sa résolution.




Fig.II.5 Frontière de décision obtenue grâce à la méthode **KFD** itérative.

II.4.3 KPCA

Toutefois, la **PCA** est une méthode linéaire qui ne détecte pas les structures non-linéaires des données. La **PCA** non linéaire rend possible l'extraction de ces propriétés grâce à l'utilisation de noyaux de Mercer de la même façon que dans le **SVM** ou le **KFD**. Nous détaillerons la **KPCA** qui fait objet de notre travail au chapitre III.

II.5 Conclusion

Plusieurs méthodes non linéaire de reconnaissance ont été présentées tout au long de ce chapitre tel que la théorie des noyaux reproduisant a permis le développement fulgurant d'une classe d'algorithmes de reconnaissance des visages dont la formulation ne dépend pas de la nature des données traitées, ni de l'espace de représentation adopté pour résoudre les problèmes. Au-delà de ce caractère universel, celles que l'on range désormais sous le qualificatif de méthodes à noyau doivent également leur succès à l'essor de la théorie statistique de l'apprentissage.

CH III :

Etude du système RV a base de
KPCA et SVM

III.1 Introduction

Différentes approches pour la reconnaissance de visage ont été présentées dans le chapitre 2. Nous nous intéressons à une méthode globale basée sur le noyau d'analyse en composantes principales (**KPCA**). Dans ce chapitre, nous présenterons donc l'algorithme de réduction d'espace : par le filtre de **Gabor** suivi de la méthode optimale au sens information le **KPCA**. Une étude théorique de cette approche et surtout son application au domaine du visage est faite. Pour pouvoir apprendre les visages, après les avoir localisés, il nous faut extraire des caractéristiques visuelles et établir des similarités sur ces caractéristiques suffisamment pertinentes. Nous étudions des caractéristiques issus de filtre de Gabor.

Le système de reconnaissance que nous avons adopté est basé sur l'algorithme de réduction d'espace par **KPCA** (Kernel Principle Component Analysis), appliqué à la représentation de la partie réelle de **Gabor**.

Finalement une classification supervisée est prévue. Pour cela, nous présentons deux classifications de nature différentes l'une basée sur la mesure de similarité et l'autre basée sur la méthode **SVM** (Support Vector Machine).

III.2 Architecture du modèle conçu

Notre modèle conçu est basée sur l'étude comparative des méthodes **PCA** et **KPCA**. L'architecture d'un tel système est résumée par les étapes suivantes selon le schéma de la figure III.1.




Fig.III.1 Système de vérification d'identité de visage

III.2.1 Etape 1 : Prétraitement de visage

Dans l'étape du prétraitement, nous regroupons tous les modules qui vont modifier la représentation sources.

L'objectif est de trouver une représentation qui facilite le travail des modules suivants. Deux types de transformation sont utilisés. Elles permettent souvent une première réduction des données et elles atténuent les effets dus à une différence de conditions lors des prises de vues [Sai 05].

Le prétraitement est une phase importante dans le processus globale d'authentification. C'est une méthode simple qui augmente en général les performances du système. Elle permet souvent une première réduction des données et elle atténue les effets d'une différence de conditions lors des prises de vues. Pour notre travail nous avons besoin de trois phases de prétraitement : le découpage de l'image puis la décimation conversion de la couleur en niveaux de gris (NG)[Oua 11].

III.2.1.1 conversion Couleur (NG)

Une image acquise habituellement appartienne à l'espace **RVB** (une combinaison de trois couleurs : Rouge- Vert- Bleu). La première étape nécessaire à la réalisation de notre projet est la traduction de l'image à traiter en niveaux de gris. Pour ce faire, il suffit de travailler sur les couleurs **RGB** de l'image. On doit préalablement récupérer les trois teintes **r**, **g** et **b**; puis les égaliser grâce à la formule suivante :

$$R=G=B=0.3*r+0.59*g+0.11*b \quad (\text{Equ.III.1})$$

Enfin, il suffit de redonner à l'image ces nouvelles composantes R, G, B. Celle-ci est alors grise. Nous avons implémenté cette fonction dans l'unique but de pouvoir travailler sur un plus grand nombre d'images. On peut également utiliser directement la fonction '**rgb2ray**' disponible sur le logiciel **Matlab**.




Fig.III.2 Image convertie au NG

III.2.1.2 Découpage

Le découpage de l'image consiste à conserver les maximums des variations intrinsèques du visage, et de supprimer les autres informations comme l'arrière plan, les cheveux, les cols de chemise, les oreilles...etc. afin d'améliorer les performances du système d'authentification.

Une fenêtre rectangulaire de taille (161x121) est centrée autour des caractéristiques les plus stables liées aux yeux, aux sourcils, au nez et à la bouche a été utilisée. La figure III.3 montre l'utilisation de cette fenêtre [Oua 11].




Fig.III.3 L'image de visage avant et après découpage

III.2.1.3 Filtrage de Gabor

Le traitement des images faciales nécessite généralement un filtrage [Oua 09].




Fig.III.4 Image filtrée

III.2.2 Etape 2 : Analyse par les ondelettes de Gabor

Une alternative à l'usage de la morphologie mathématique est l'application d'une transformée d'ondelette. Les ondelettes de Gabor sont connues comme le moyen d'analyse espace-fréquence qui minimise l'incertitude de Heisenberg à savoir si on est précis dans l'analyse de l'information dans l'espace du pixel on le sera moins dans l'espace fréquentiel et vice versa. Cette caractéristique fait des ondelettes de Gabor un moyen puissant pour l'analyse

de la texture. Elles ont été développées au début pour l'analyse des signaux à une dimension. Leurs expression générale est :

$$W(t, t_0, \omega) = e^{-\sigma(t-t_0)^2} e^{-i\omega(t-t_0)} \quad (\text{Equ.III.2})$$

où ω est la fréquence et $i^2 = -1$. Cette ondelette est en fait une gaussienne modulée par une fonction sinusoïdale. La généralisation de cette fonction en **2D** donne une fonction gaussienne à deux dimensions modulée par une harmonique. Les ondelettes de Gabor **2D** ont la caractéristique d'être modulable par différents paramètres qui contrôlent leurs orientations, fréquences, phases de la sinusoïde, Le support temporel, L'enveloppe de la gaussienne. L'équation générale d'une ondelette de Gabor en **2D** est :

$$W(x, y, \theta, \lambda, \varphi, \sigma, \gamma) = e^{-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}} e^{i(\frac{x'}{\lambda} + \varphi)} \quad (\text{Equ.III.3})$$

Où : $x' = x \cos \theta + y \sin \theta$ et $y' = -x \sin \theta + y \cos \theta$.

Il y a donc 5 paramètres qui contrôlent l'analyse par ondelette. Ce jeu de paramètres permet dès lors une analyse complète de la texture d'une région de l'image.

III.2.2.1 L'orientation de l'ondelette (θ)

Ce paramètre fait pivoter l'ondelette autour de son centre. L'orientation de l'ondelette (Fig.III.5) détermine l'angle des contours ou des lignes de l'image auxquelles l'ondelette va être sensible.




Fig.III.5 Orientation de l'ondelette.

- θ spécifie l'orientation du filtre. Nous utilisons dans ce cas huit orientations : $\theta = \{0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8\}$.

III.2.2.2 La fréquence centrale de l'ondelette (λ)

Ce paramètre spécifie la longueur d'onde du cosinus ou inversement la fréquence centrale de l'ondelette (Fig.III.6). Les ondelettes avec une grande longueur d'onde seront

sensibles à des changements progressifs d'intensité dans une image. Les ondelettes avec une petite longueur d'onde seront sensibles à des contours et des lignes abruptes,




Fig.III.6 La fréquence centrale de l'ondelette (λ)

- λ spécifie la longueur d'onde et donc la fréquence de la sinusoïde. Cette variable peut prendre cinq valeurs comprises entre 4 et 16 : $\lambda = \{4, 4\sqrt{2}, 8, 8\sqrt{2}, 16\}$.

III.2.2.3 La phase de la sinusoïde (φ)

On utilise à la fois la partie réelle et la partie imaginaire de l'ondelette complexe de Gabor. Ce qui nous donne, en quelque sorte, deux ondelettes : une ondelette paire et une ondelette impaire. La convolution (incluant alors deux phases) donne un coefficient complexe basé sur deux ondelettes qui sont déphasées de $\pi/2$ (Fig.III.7),




Fig.III.7 Phase de l'ondelette.

- φ spécifie la phase de la sinusoïde. Elle vaut 0 ou $\pi/2$ selon que l'on veut la partie réelle ou imaginaire.

III.2.2.4 Le support temporel de l'ondelette (σ)

Ce paramètre spécifie le rayon de la gaussienne (Fig.III.8). La taille de la gaussienne détermine la quantité de pixels de l'image qui vont être pris en compte dans la convolution,




Fig.III.8 Support temporel de l'ondelette.

- σ spécifie la variance de la gaussienne (sa taille ou résolution). Elle est proportionnelle à la longueur d'onde de la sinusoïde. Dans notre cas $\sigma = \lambda$.

III.2.2.5 L'enveloppe de la gaussienne (γ)

Ce paramètre agit sur la forme de l'enveloppe gaussienne, en l'étirant spatialement (Fig.III.9). Ce paramètre a été inclus de manière à ce que les ondelettes puissent approximer certains modèles biologiques. La plupart des ondelettes testées avec l'algorithme [Oua 11].




Fig.III.9 Forme de l'enveloppe gaussienne.

- γ spécifie l'aspect de la gaussienne. Ici les gaussiennes sont de forme circulaire : $\gamma = 1$.

La représentation de Gabor d'une image de visage est obtenue par la convolution de l'image avec la famille des filtres de Gabor, définie par $IG(r, \theta) = I * G(r, \theta)$ où $IG(r, \theta)$ est le résultat de la convolution de l'image par le filtre de Gabor à une certaine résolution r et à une orientation θ .

La famille de filtres de Gabor est alors caractérisée par un certain nombre de résolutions ou fréquences et orientations, qui seront appelées "caractéristiques" par la suite. A partir de cette expression, une fonction en **MATLAB** génère un filtre de **Gabor** avec la méthode d'échantillonnage en fréquence [Oua 09].

Function [**G**, **GABOUT**] = **gaborfiltre** (**I,S ;F,W ;P**) ;

G : filtre de **Gabor**.

GABOUT : la transformation de **Gabor**.

Les paramètres d'entrée de cette fonction doivent être la variance **S**, les coordonnées polaires de la fréquence (**F,W**) et l'orientation **P**.

III.2.3.Etape 3 : La réduction d'espace par KPCA

L'intérêt porté à la PCA pour résoudre des problèmes d'apprentissage a été récemment relancé par l'obtention d'une version non-linéaire de cet algorithme : la **KPCA**. En effet, tel qu'il a été présenté ici, il ne s'appuie que sur des dépendances **linéaires** entre les variables et cela restreint considérablement son efficacité. La **KPCA** permet d'exploiter des relations potentiellement non-linéaires entre les variables. On décrit maintenant comment la non-linéaire est introduite [Lau 05].

Les objets ne sont plus supposés de nature vectorielle : ils appartiennent à l'espace des entrées **X** qui est quelconque. La version non-linéaire de la **PCA** repose sur un principe général permettant d'obtenir des versions non-linéaires d'algorithmes : *l'astuce du noyau*. Ce principe est aussi utilisé pour l'algorithme des **SVM**. Il consiste à envoyer préalablement les données X_j par une application $\phi: X \rightarrow \mathcal{H}$ (appelée feature map) dans une espace linéaire de grande dimension \mathcal{H} muni d'un produit scalaire. Les nouveaux individus sont alors les vecteurs $\phi(X_j), j = 1 \dots n$. La **KPCA** correspond à une **PCA** dans un espace de grande dimension \mathcal{H} .

Les colonnes de la matrice **T** sont maintenant constituées des coordonnées des $\phi(X_j)$ et celles de la matrice \tilde{T} des coordonnées des $\widehat{\phi}(X_j) = \phi(X_j) - \frac{1}{n} \sum_{j=1}^n \phi(X_j)$. La matrice de covariace à diagonaliser est

$$\widehat{\Sigma} = \frac{1}{n} \sum_{j=1}^n (\phi(X_j) - \bar{\phi})(\phi(X_j) - \bar{\phi})' \quad (\text{Equ.III.4})$$

Ou $\bar{\phi} = \frac{1}{n} \sum_{j=1}^n \phi(X_j)$ est le centre de gravité du nuage des individus envoyés dans \mathcal{H} . Par souci de clarté, l'espace \mathcal{H} est supposé de dimension finie mais le principe reste le même s'il est de dimension infinie. Il suffit de considérer des opérateurs à la place des matrices.

La « feature map » $\bar{\phi}$ n'est pas connue explicitement : on ne la connaît que par ses produits scalaires

$$\langle \phi(x_1), \phi(x_2) \rangle = k(x_1, x_2) \quad (\text{Equ.III.5})$$

Où k est une fonction connue à l'avance et appelée *noyau*. Afin d'obtenir l'algorithme de la **KPCA**, il faut donc pouvoir calculer les vecteurs propres de $\widehat{\Sigma}$. par extension du cas linéaire, ces vecteurs propres sont encore appelés *directions principales* : il est important de noter que ce sont des vecteurs de \mathcal{H} . Cette diagonalisation engendre deux difficultés d'ordre algorithmique. D'une part, $\widehat{\Sigma}$ est une matrice de grande dimension et sa diagonalisation peut donc être difficile. D'autre part la matrice $\widehat{\Sigma}$ n'est pas connue explicitement puisqu'elle fait intervenir la matrice des caractéristiques (feature map). Ces problèmes sont résolus en introduisant la *matrice noyau*.

Soit $\bar{K} = \frac{1}{n} \bar{T}' \bar{T}$. Un résultat classique d'algèbre linéaire stipule que \bar{K} et $\widehat{\Sigma} = \frac{1}{n} \bar{T}' \bar{T}$ ont les mêmes valeurs propres non-nulles. De plus, si \widehat{w}_i est un vecteur propre de \bar{K} , $\widehat{y}_i = \bar{T} \widehat{w}_i$ est un vecteur propre de $\widehat{\Sigma}$. Si on considère des vecteurs propres orthogonaux de \bar{K} , les vecteurs propres correspondants de $\widehat{\Sigma}$ sont eux aussi orthogonaux. Finalement, pour diagonaliser $\widehat{\Sigma}$, il suffit de diagonaliser la matrice symétrique \bar{K} de taille n .

La matrice noyau (ou matrice de Gram) \mathbf{K} est une matrice carrée de taille n accessible uniquement à partir du noyau et des données dont la diagonalisation permet accéder aux vecteurs propres de $\widehat{\Sigma}$. Précisément, on a :

$$\widehat{y}_i = \sum_{j=1}^n \widehat{w}_i^j \widehat{\phi}(X_j) \quad (\text{Equ.III.6})$$

Où \widehat{w}_i^j désigne la j^e coordonnée du vecteur \widehat{w}_i et \widehat{y}_i est un vecteur propre de $\widehat{\Sigma}$ associé à la i^e plus grande valeur propre non-nulle de $\widehat{\Sigma}$. L'expression (Equ.III.6) fait encore intervenir la feature map. Cela ne pose pas de difficultés puisque qu'on peut exprimer la projection de n'importe quel élément de la forme $\phi(x) - \bar{\phi}$ sur la droite engendrée par \widehat{y}_i uniquement en fonction des valeurs de la fonction k grâce à la relation (Equ.III.5). Soit

$f_i(x) = \langle \phi(x) - \bar{\phi}, \widehat{Y}_i \rangle$ la projection de l'image d'un point x quelconque de l'espace \mathbf{X} sur \widehat{y}_i . Contrairement à la **PCA**, les courbes de niveau de f_i dépendent non-linéairement de x .

La **KPCA** nécessite-la donnée à priori d'une fonction k liée à une application ϕ par la relation (Equ.III.5). la section $Corr(W_1, W_2) = \frac{Con(W_1, W_2)}{\sqrt{var(W_1)var(W_2)}}$ donne une condition nécessaire et suffisante sur k assurant l'existence de la feature map .

Formellement, les propriétés de la **PCA** se généralisent à la **KPCA** en remplaçant les individus \widehat{X}_i par $\widehat{\phi}(X_i)$. L'espace choisi par la **KPCA** est celui engendré par les d premières directions principales :

$$\widehat{V}_d = \langle \widehat{Y}_1, \dots, \widehat{Y}_d \rangle \quad (\text{Equ.III.7})$$

Ou \hat{Y}_i désigne un vecteur propre associé à la i^e plus grande valeur propre non-nulle de l'opérateur $\hat{\Sigma}$ défini par (Equ.III.4). La somme des grandes (resp petites) valeurs propres de la matrice noyau recentrée \bar{K} permet de quantifier la quantité de variance prise en compte par l'espace \hat{V}_d (resp l'erreur quadratique de reconstruction) [Lau 05].

III.2.4 Etape 4 : SVM (Machine à Vecteur de Support)

Les machines à vecteurs de support (Support Vector Machine : **SVM**), également appelés Séparateurs à Vaste Marges, introduits par Vapnik, ont pour but de définir un hyperplan de séparation entre les deux classes, hyperplan qui minimise l'erreur de classification sur un ensemble d'apprentissage. Cette méthode d'apprentissage supervisée peut apprendre une séparatrice plus ou moins complexe selon la nature du noyau choisi. Le noyau le plus simple est le noyau linéaire qui correspond à chercher un séparateur linéaire dans l'espace à N dimensions des scores. Le but des fonctions noyau est de transformer l'espace initial (des scores à N dimensions) en un espace de dimension plus grande dans lequel les données pourraient être linéairement séparables. La séparatrice est donc toujours linéaire dans l'espace transformé par la fonction noyau, mais ne l'est plus dans l'espace des scores [Oua 11]. Heisele et al. utilisent des machines à vecteur de support (**SVM**) dans le cadre de la reconnaissance de visages par des méthodes globales ainsi que par des méthodes reposant sur des traits caractéristiques [Fra 04].

Le but du **SVM** est donc de trouver une séparatrice qui minimise l'erreur de classification sur l'ensemble d'apprentissage mais qui sera également performante en généralisation sur des données non utilisées en apprentissage. Pour cela le concept utilisé est celui de marge (d'où le nom de séparateurs à vaste marge). La marge est la distance quadratique moyenne entre la séparatrice et les éléments d'apprentissage les plus proches de celle-ci appelés vecteurs de support. Ces éléments sont appelés vecteurs de support car c'est uniquement sur ces éléments de l'ensemble d'apprentissage qu'est optimisée la séparatrice.




Fig.III.10 Séparation linéaire dans un espace à deux dimensions.

Tout classifieur a pour but de classifier un élément x , ici $x = (s_1, \dots, s_N)$ est un vecteur de scores de dimension N , dans l'une des classes possibles. Dans notre problème il y a deux classes, Client ou Imposteur, dont l'étiquette sera noté y avec $y = -1, 1$ correspondant à la classe des Imposteurs et 1 à la classe des Clients. Le classifieur a donc pour but de déterminer f telle que :

$$y = f(x) \quad (\text{Equ.III.8})$$

Le **SVM** a pour but de trouver la meilleure séparatrice linéaire (en terme de marge maximale, c'est à dire la meilleure généralisation) dans l'espace transformée par la fonction de noyau K , c'est à dire de déterminer le vecteur w et la constante b tels que la séparatrice ait pour équation :

$$w \cdot k(x) + b = 0 \quad (\text{Equ.III.9})$$

La distance entre un point de l'espace x_i et l'hyperplan d'équation $w \cdot K(x) + b = 0$ est égal à :

$$h(x_i) = \frac{w \cdot K(x_i) + b}{\|w\|} \quad (\text{Equ.III.10})$$

Pour maximiser la marge, il faut donc minimiser $\|w\|$ tout en maximisant $w \cdot K(x_i) + b$ pour les x_i définis comme vecteurs de support. Ces vecteurs de supports sont les x_i pour $i = 1 : m$ de la base d'apprentissage tels que $w \cdot K(x_i) + b = \pm 1$.

La résolution de ce problème d'optimisation est faite par l'utilisation des multiplicateurs de Lagrange où le Lagrangien est donné par :

$$L(w, b, \alpha) = \left(\frac{1}{2}\right) \|w\|^2 - \sum_{i=1}^m \alpha_i (y_i (w \cdot K(x_i) + b) - 1) \quad (\text{Equ.III.11})$$

avec les coefficients α_i appelés multiplicateurs de Lagrange. Pour résoudre ce problème d'optimisation, il faut minimiser le Lagrangien par rapport à w et b et le maximiser par rapport à α .

Dans la pratique, il est souvent impossible de trouver un séparateur linéaire (même dans l'espace transformé par la fonction noyau) car il y a toujours des erreurs de classification. Il a donc été introduit par Vapnik la technique de marge souple. Ce principe de marge souple tolère les mauvais classements par l'introduction de variables ressorts ζ_i qui permettent de relâcher les contraintes sur les éléments d'apprentissage qui ne doivent plus être à une distance

supérieure ou égale à 1 de la marge (l'égalité correspondant aux vecteurs de support), mais à une distance supérieure ou égale à $1 - \zeta_i$, c'est à dire :

$$y_i(w \cdot K(x_i) + b) \geq 1 - \zeta_i \quad (\text{Equ.III.12})$$

avec $\zeta_i \geq 0$ pour $i = 1 : M$, M étant le nombre d'éléments de la base d'apprentissage.

Le problème d'optimisation est donc modifié et le Lagrangien devient :

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^M \xi_i - \sum_{i=1}^M \alpha_i (y_i(w \cdot K(x_i) + b) - 1) \quad (\text{Equ.III.13})$$

où C est une constante strictement positive qui permet de régler le compromis entre le nombre d'erreurs de classification et la largeur de la marge. Cette constante est en général déterminée empiriquement par validation croisée sur l'ensemble d'apprentissage [Oua 11].

Dans une machine à vecteurs de support (**SVM** pour Support Vector Machine), les données sont projetées de manière implicite dans un nouvel espace par l'intermédiaire de la définition du produit scalaire entre points projetés, qui est susceptible pour appliquer un algorithme de classification linéaire robuste dans cet espace (Boser et al., 1992; Cortes and Vapnik, 1995). Plus précisément, si la projection est f_D , l'algorithme de classification n'utilise pas directement f_D , mais uniquement la fonction

$$K_D(x, x') = f_D(x) \cdot f_D(x')$$

Le problème de l'extraction de caractéristiques est alors directement relié à celui de l'apprentissage du noyau. Il s'agit d'un domaine de recherche très actif, car en pratique le noyau utilisé peut avoir une influence cruciale sur les performances en classification. Les différentes méthodes proposées à cet effet dans la littérature ont été répertoriées dans les revues de Yang and Jin (2006) et Yang (2007). Notons qu'une telle extraction de caractéristiques implicite est commune à tous les algorithmes utilisant l'astuce du noyau, et que le cas des **SVMs** présenté ici n'en est que l'exemple le plus répandu en apprentissage machine [Oli 08].

Depuis son introduction dans le domaine de la Reconnaissance de Formes (**RdF**), plusieurs travaux ont pu montrer l'efficacité de cette technique principalement en traitement d'image.

L'idée essentielle consiste à projeter les données de l'espace d'entrée (appartenant à des classes différentes) non linéairement séparables, dans un espace de plus grande dimension

appelé espace de caractéristiques, de façon à ce que les données deviennent linéairement séparables [You 08].

Dans cet espace, la technique de construction de l'hyperplan optimal est utilisée pour calculer la fonction de classement séparant les classes tels que :

- Les vecteurs appartenant aux différentes classes se trouvent de différents côtés de l'hyperplan.
- La plus petite distance entre les vecteurs et l'hyperplan (la marge) soit maximale [Adj07].




Fig.III.11 Frontière de décision non linéaire

III.3 CONCLUSION

Dans ce chapitre nous avons présenté les différentes étapes du système de reconnaissance de visage. Notre choix s'est porté sur le filtrage et la compression de données par le filtre de Gabor puis l'extraction des paramètres caractéristiques par la **PCA** et la **KPCA** et finalement une classification conçue à base de **SVM**. Dans le chapitre suivant nous présenterons l'implémentation de ce modèle et son application à une base de données universelle la **XM2VTS**. Et une étude comparative est menée.



CH IV :

Conception et étude
comparative



*INTRODUCTION
GENERALE*



*CONCLUSION
GENERALE*

IV.1 Introduction

Afin de mesurer les performances d'un système de reconnaissance de visages, les scientifiques ont établi un certain nombre de règles communes permettant de disposer les mêmes critères d'évaluation. Ces critères s'appliquent sur des bases de données également communes et partagées par l'ensemble de la communauté scientifique. Une base de données regroupe plusieurs images de plusieurs personnes.

IV.2 La base de données XM2VTS

Cette base de données **XM2VTS** a été prolongée de **M2VTS** (Multi Modal Vérification for Teleservices and Security applications), par le centre **CVSSP** (Centre for Vision, Speech and Signal Processing), de l'université de Surrey, en grande Bretagne, dans le cadre du projet européen **ACTS** qui traite le contrôle d'accès par une vérification multimodale d'identité, afin de comparer les différentes méthodes de vérification d'identité [Oua 11].

Nos expériences ont été exécutées sur des images frontales de visage de la base de données **XM2VTS**. Cette base est une base de données multimodale publiquement disponible enregistrée spécifiquement pour évaluer les exécutions des approches biométriques à la vérification d'identité. Elle contient 8 images par visage de 295 personnes. Les sujets ont été enregistrés en quatre sessions séparées distribuées pendant 5 mois. Le protocole expérimental standard lié à la base de données divise la base de données en 200 clients et 95 imposteurs. Les sujets sont des deux sexes, proviennent de diverses ethnies et de catégories d'âge différentes. Les photos sont en couleur, de haute résolution (format ppm), la taille est de 256 x 256 pixels pour les images et de très bonnes qualités codées sur 24 bits dans l'espace **RVB**. Cela permet de travailler en niveaux de gris ou en couleur.

Le choix principal de **XM2VTS** est sa taille grande, avec 295 personnes et 2360 images en total et sa popularité puisqu'elle est devenue une norme dans la communauté biométrique audio et visuelle de vérification multimodale d'identité [Oua 11].

Il n'est pas suffisant d'utiliser la même base de données pour pouvoir honnêtement comparer des résultats. Il est nécessaire également de définir un protocole de test. Dans le protocole de Lausanne la base de données est scindée en trois ensembles : ensemble d'apprentissage, ensemble d'évaluation et ensemble de test. L'ensemble d'apprentissage est utilisé comme ensemble de référence. Il sert d'ensemble de base, maintenant ainsi l'information concernant les personnes connues du système. L'ensemble d'évaluation permet de fixer les paramètres du système de reconnaissance de visages.

En fait, l'ensemble de test permet de tester le système en lui présentant des images de personnes lui étant totalement inconnues.

Enfin, la base de données est divisée en deux classes : clients est imposteurs. L'ensemble d'apprentissage ne contient que des clients. Les imposteurs sont répartis dans les deux autres ensembles, à raison de 25 pour l'ensemble d'évaluation et 70 pour l'ensemble de test.

IV.3 Environnement de programmation

IV.3.1 Implémentation du Programme

Nous avons implémenté le système de vérification de visage dans l'environnement de programmation *MatLab 9* qui offre une grande simplicité de manipulation des images. Ce langage possède des avantages très intéressants pour les applications sur l'image tel que:

- la portabilité de logiciel (simplifie le processus de programmation sous Windows).
- L'utilisation des bases de données.
- Facilité de manipulation des matrices ce qui est fort important dans le cas de notre application.
- Un large choix de bibliothèques qui prennent en charge tous les outils mathématiques utiles au traitement et à l'analyse des images.

Pour augmenter la lisibilité de notre programme et faciliter les différents tests nécessaires, nous avons essayé de le partitionner en un ensemble de modules.

IV.3.2 Modules du programme

Ce système est divisé en 3 modules principaux :

IV.3.1.1 Module 1 : Prétraitement et détection est la phase fondamentale d'un système de reconnaissance de visage. Elle est composée de deux blocs essentiels : le **prétraitement** (basé sur le **filtrage de Gabor** réalisé après une étape de **conversion** de l'image couleur en Niveaux de Gris) et la **détection** (que nous avons réalisé par l'opération de **découpage**)

IV.3.1.2 Module 2 : Extraction de paramètres qui effectue l'extraction des caractéristiques obtenus en calculant la **KPCA** de la matrice de covariance de l'image filtrée par le filtre de **GABOR** après une opération de découpage et de conversion de la couleur en **NG** à partir de l'image de visages d'entrée, on calcule ainsi un vecteur transformé par **KPCA** composant le vecteur de caractéristiques faciales de chaque image de visage. L'algorithme de l'extraction par une technique basée sur une méthode d'analyse statistique qui est présenté

dans la partie conception, le vecteur de caractéristiques faciales ainsi obtenu par la projection de l'image dans un sous espace est soumis à la phase classification.

IV.3.1.3 Module 3 : Classification

- **Classification par mesure de similarité** : C'est une méthode reposant sur une mesure de similarité des visages. Ce type de classification sera à la base de notre étude comparative.

- **Classification par SVM** : est une mise en œuvre d'un réseau SVM présenté dans le chapitre III. Après une phase d'apprentissage, ce réseau fournit la réponse de la vérification des images de visage. Cette classification reste efficace mais complexe.

IV.4 Architecture d'un système de reconnaissance de visage

IV.4.1. Organigramme d'apprentissage




Fig. IV.1 Organigramme d'apprentissage

IV.4.2. Organigramme de test




Fig. IV.2 Organigramme de test




Fig. IV.3 Organigramme du système de vérification d'identité de visage

IV.5 Modules du système

Une diversité de structures de données a été utilisée selon nos besoins, tel que les tableaux, les matrices, les listes, les fichiers, etc.

Dans ce qui suit, nous essayons de donner les algorithmes des modules les plus importants de notre application.

IV.5.1 Module de prétraitement

Ce module contient les procédures de transformation l'image couleur en niveaux de gris, de découpage et d'un filtrage

IV.5.1.1 Conversion couleur NG et découpage d'une image

Notre image originale est en couleurs **RGB** pour la convertir en **NG**, on doit préalablement récupérer les trois teintes r, g, b puis les égaliser à la formule suivante:

$$R=G=B =0.3*r+0.59*g+0.11*b$$

Il suffit de redonner l'image ces nouvelles composantes R, G, B

Enfin on peut utiliser directement la fonction **rgb2gray** disponible en **Matlab**

*/*Algorithme de conversion RGB au NG*/*

Pour tout les pixels d'image 1

r ← champ rouge (image 1 pixels)

v ← champ vert (image 1 pixels)

b ← champ bleu (image 1 pixels)

*Y ← ((0.299*r)+(0.587*v)+(0.114*b))*

Image2 pixel ← RGB(Y,Y,Y)

Le découpage est une opération réalisée après la conversion de l'image à traiter en niveaux de gris. L'image est découpée par une fenêtre rectangulaire de taille 123x120 centrée autour des caractéristiques les plus stables liées aux yeux, aux sourcils au nez et à la bouche

Pour cela, nous utilisons la fonction **imcrop** () incluse en **Matlab**

IV.5.1.2 Filtrage de l'image

On utilise un filtre de **Gabor** qui définit par les équations suivantes :

$$G(X, Y) = EXP \left((0,5) * \left(\frac{(X_1)^2 + (X_2)^2}{S^2} \right) * EXP \left(i * \left(\frac{X_1}{Lahnda} + phi \right) \right) \right)$$

$$X_1 = X * \cos(téta) + Y * \sin(téta)$$

$$Y_1 = -X * \sin(téta) + Y * \cos(téta)$$

Pour son implémentation nous utilisons fonction **MATLAB**

[G ; GABOUR] = GABOUR filter (I, S, TETA, LAMDA, PHI)

- **Téta** spécifie l'orientation du filtre.
Téta = (T= 0, pi/8, pi/4, 3pi/8, pi/8, 5pi/8, 3pi/4, 7pi/8)
- **Lahnda** spécifie la longueur d'onde et donc la fréquence de la sinusoïde.
Lahnda = (4, 4*√2, 8, 8*√2, 16) = (L=4, 5.657, 8, 11.313, 16)
- **Phi** spécifie la phase de la sinusoïde. Elle vaut **0** ou **pi/2** selon que l'on veut la partie réelle ou imaginaire.
- **S** spécifie la variance de la gaussienne (sa taille). Elle est proportionnelle à la longueur d'onde de la sinusoïde.

Fonction filtrage / Algorithme du filtre de Gabor*/*

Pour

X= -fix(S) :fix(S)

Pour Y= -fix(S) :fix(S)

*XI= X*cos(teta)+Y*sin(teta) ;*

*YI= -x*sin (teta)+Y*cos (teta) ;*

G(fix(S) +X+1,fix(S)+Y+1) = exp ((-0,5)((XI*

^2+(bci(YI)^2))/S^2)*exp (I*X1/(lahnda+phi));*

fin

fin

Gabor=conv2 (I double ((G)), 'same');

fin

Et enfin, on a l’algorithme général du prétraitement :

```

X : image d'entrée (a traiter)./* Algorithme de pretraitement avec le filtre Gabor*/
%%%%%%
Prétraitement(X) /*X :image originale*/
Lire X
Transférer X de RGB niveaux de gris
(S=rgb2ray(X)) /*S : image en NG*/
Découper S → Y
Pour: T=0,π/8, 2π/8, 3π/8, 4π/8, 5π/8, 6π/8, 7π/8 ;
 Pour :L=4,5.657,8,11.313,16
 Filtre Y par : le filtre de Gabor
Filtre de Gabor dans un seul vecteur(G)/*G :vecteur image filtré parGabor*/
Afficher de l'abs du filtre de Gabor (G)
Afficher de l'angle du filtre de Gabor(G)
Fin
Fin
Enregistrer G
    
```




Fig. IV.4 Exemple de prétraitement d’une image

IV.5.2 Extraction de paramètres

IV.5.2.1 Schéma fonctionnel de la KPCA




Fig. IV.5 Schéma fonctionnel de la KPCA

IV.5.2.2 L'algorithme de KPCA

```

Procédure de calcul KPCA /* Algorithme de KPCA*/

Fonction noyau Gaussien

x,y : deux coord.points

Param=0.5/sigma*sigma      *paramètre de la fonction kernel.*
                           *sigma: la largeur du noyau Gaussien*

- Function k=kernel (x,y,param)

    Diff=x-y;

    K = exp(-(dif*diff)*param);

function KPCA (data,sigma,numev,outlier)*

    [n,d]=size (data); /matrice de n lignes et m colonnes

    *centrer les données de la matrice noyau *

    K=zero(n,n);

    *Calcul de la matrice de covariance*

    Calculer la matrice de covariance c'est le produit de la matrice
    centrée et sa transposée.

    *Calcul des valeurs et vecteurs propres*

    Calculer les valeurs propres et les vecteurs propres par la fonction
    eig();

    *Tri des valeurs propres par ordre décroissant *

    Trier les valeurs propres  $\lambda$  dans l'ordre décroissant avec la fonction
    sort();

fin

```

IV.5.3 La classification

IV.5.3.1 Mesures de similarités

Nous avons deux types de distances :

- **La distance_intra** : la distance entre deux images de visage de même individu.
- **La distance_extra** : la distance entre deux images de visage de deux individus différents.

Dans le problème de vérification d'identité, nous cherchons à définir, pour chaque personne, ou de manière globale un seuil. Ce seuil va déterminer le minimum de ressemblance entre deux images pour admettre qu'il s'agit de la même personne. Ce minimum de ressemblance va s'exprimer comme une distance maximale entre les caractéristiques des deux images. Pour fixer ce seuil nous allons utiliser l'ensemble d'évaluation. Théoriquement, le **max(distance_intra) < min (distance_extra)** dans cette condition, il est possible de déterminer un seuil S qui détermine une classification parfaite (sans erreurs). Il suffit de prendre :

$$S = (\max(\text{distance}_{intra}) + \min(\text{distance}_{extra}))/2$$

Une fois que les images sont projetées dans un sous espace il reste à déterminer quelles sont les images, semblables... Il y a beaucoup de mesures possibles de distance et de similitude, parmi lesquelles on cite:

- La norme **L1**

La norme L1 entre deux vecteurs A et B c'est la somme des valeurs absolue de la différence entre les composantes des deux vecteurs A et B . Elle est donnée par la relation suivante :

$$L_1 = \sum_{i=1}^N |A_i - B_i|$$

- La norme **L2**

Connue aussi sous le nom norme euclidienne, c'est la somme du différence carré entre les composantes des deux vecteurs A et B . Elle est donnée par l'équation suivante:

$$L_2 = \sum_{i=1}^N (A_i - B_i)^2$$

- Covariance (Angle)

La covariance est une mesure d'angle. Elle calcule l'angle entre deux vecteurs normaux. Elle est donnée par :

$$\text{cov}(A, B) = \frac{A \cdot B}{\|A\| \|B\|}$$

IV.5.3.2 Algorithme de calcul de TFA, TFR et seuillage

```

%DIS_CL : intervalle des distances intra
%DIS_IMP intervalle des distances extra
%TFR : taux de fausse acceptation.
%seuil : le seuil pour avoir TFR=TFA
.....
% Algorithme

Max_INT= max (max(DIS_CL),min(DIS_IMP)) ;
min_INT= min (max(DIS_CL),min(DIS_IMP)) ;
Seuil =(min_INT+max_INT)/2 ;

% Calculer TFA, TFR
TFA= (length(find(DIS_IMP<SEUIL)) /length(DIS_IMP))*100;
TFR= (length(find(DIS_IMP>SEUIL)) /length(DIS_CL))*100;
Tant que (abs(TFA-TFR)>10^(-2))
Si TFA>TFR
Max_INT =seuil ;
Seuil= (max_INT+min_INT) /2 ;
Si non
Min_INT=seuil ;
Seuil=(min_INT+max_INT) /2 ;
Fin
TFA= (length(find(DIS_IMP<SEUIL)) /length(DIS_IMP))*100;
TFR= (length(find(DIS_IMP>SEUIL)) /length(DIS_TMP))*100;
Fin

```

Fig. IV.6 Algorithme de calcul de TFA, FFR et seuillage.

IV.5.3.3 SVM (Apprentissage)

La classification par **SVM** s'avère assez efficace aussi nous tentons de l'utiliser dans le cadre de notre travail et tester ses performances, nous avons utilisé le **LS-SVMlab** qui a été conçu dans l'environnement **MATLAB** et qui s'adapte avec la **KPCA** pour le cas des séparations non linéaires.

Chaque boîte contient les noms des algorithmes correspondants. Les noms de fonctions avec l'extension "**lssvm**" sont spécifiques méthode **LS-SVM**. La zone en pointillés comprend toutes les fonctions d'une boîte à outils les plus avancés, la zone grise de grandes personnes qui sont inclus dans la version de base.

Pour l'apprentissage de **SVM** on utilise la fonction **trainlssvm** contenue dans **LS-SVMlab** qui a pour paramètres la matrices d'apprentissage, le groupe de chaque image contenue dans la matrice, les deux paramètres **gamma** et **sigma**, le type de **SVM** classification ou régression, et qui a pour sortie les deux paramètres **alpha** et **b**.

Pour représenter le résultat de l'apprentissage on utilise la fonction **plotlssvm** qui représente les deux classes séparé par l'hyperplan calculé.

IV.5.3.4 SVM (Vérification)

Pour la vérification (classification) des images tests clients ou imposteurs on utilise la fonction **simlssvm()** qui prend pour paramètres tous les paramètres pris pour l'apprentissage plus la matrice des images qu'on veut classer. La sortie de cette fonction est un vecteurs du nombre d'images a classier chaque élément 'i' de ce vecteur est la classe de l'image 'i' de la matrice.

Pour calculer le taux d'erreur dans la classification on utilise la fonction **missclass()** en sortie de cette fonction on trouve trois variables :

- Taux d'erreur du système
- Nombre de fausse classification
- Rang des images mal classifié

IV.6 Résultats Expérimentaux

IV.6.1 Applications dans la base d'évaluation

IV.6.1.1 Application de KPCA dans la BDD évaluation avec le filtre Gabor

Le tableau IV.5 illustre les valeurs des différents taux de performances du système de reconnaissance de visages. Nous fixons les paramètres du filtre de Gabor $T=0$ (Orientation du filtre) c'est le cas du filtre retenu, ainsi que $S=1$ (Variance de la Gausséenne associé au Kernel de la KPCA). Nous menons nos expériences dans le cas des distances L_2 et L_3 les plus optimales dans le SRV [Oua 11]. Notre approche réalisée à base de la KPCA étant appliquée à la BDD évaluation et pour les différents nombre de paramètres caractéristiques N_p a donné les résultats suivants :

Paramètres de GABOR			Nombre de paramètre	Ensemble Evaluation			
S	T	L		N_p	TET%	TFR%	TFA%
1	0	3	10	22.72	23	22.45	77.28
			50	14.28	14.33	14.23	85.72
			60	13,80	13.83	13.77	86.20
			100	10.78	10.83	10.73	89.22
			400	8.99	8.66	9.25	91.04
			500	9.40	9.5	9.31	90.60
			600	9.24	9.5	8.99	90.75
1	0	2	10	21.17	21.02	21.33	78.82
			50	15.07	15.16	14.98	84.93
			60	15.01	15	15.02	84.99
			100	12.71	13	12.43	87.28
			400	8.39	8.33	8.46	91.60
			500	9.29	9.16	9.42	90.71
			600	9.18	9.33	9.07	90.82

Tab. IV.1 Application de KPCA dans la BDD évaluation avec le filtre Gabor

S : Variance de la Gausséenne.

L : Distances. Dans notre cas nous utilisons la norme Euclidéenne L_2 et L_3 .

T : Orientation du filtre.

Le meilleur résultat obtenus pour l'application de KPCA est $TR=91.6\%$ pour L_2 . Nous remarquons que le maximum du taux de réussite est atteint pour $N_p = 400$ dans le cas des deux distances L_2 et L_3 .




Fig. IV.7 La courbe du TR pour la **KPCA** avec **Gabor** pour **L₂** et **L₃**

Les courbes montrent bien une stabilité dans le taux de réussite à partir de **N_p = 400**. Ce qui prouve bien le bon fonctionnement de la **KPCA**. Qui comme la **KPCA** contient le maximum d'information dans l'échantillon des premières valeurs propres. Donc, les **400** paramètres caractéristiques de chaque image sont représentatifs.

IV.6.1.2 Taux de reconnaissance dans l'ensemble d'évaluation et l'ensemble de test

Taux de reconnaissance dans l'ensemble d'évaluation et l'ensemble de test pour la norme **L₂** et, $\sigma = \{0.0004, 0.0007, 0.00085, 0.0009, 0.003, 0.01\}$.

		0.0004		0.0007		0.00085		0.0009		0.003		0.01	
		TR eva(%)	TR tst(%)										
NP	10	5	5	8.33	7	10.16	9.5	8.66	11	15.16	15.5	19.83	21.5
	50	67.5	80	70.5	79	70.16	79.5	70.33	80.5	71.83	83	73.16	82.5
	60	69.33	84.5	71.66	87.5	72.33	85.5	72.16	86	73.5	83.5	73.33	85.5
	100	78.83	83.5	75.33	81	77.16	84	76.83	84	81	89.5	82.16	88
	200	83.33	92.5	83.83	94.5	84.16	94	83.83	94	84.66	94.5	82.83	91.5
	400	86.66	95.5	86.83	95	87	95	87	95	86.33	96.5	85	93.5
	600	86.83	97.5	87	97	87.33	96.5	87.33	96.5	86.83	95.5	82.83	94

Tab. IV.2 Taux de reconnaissance pour **N_p** et **σ** variables dans les deux ensembles.

Les courbes des figures représentant le **TR** pour différents valeurs de σ et N_p dans l'ensemble d'évaluation et de test.

VI.6.3 Comparaison du taux de reconnaissance pour différentes σ et différents N_p dans l'ensemble d'évaluation :




Fig IV.8 : Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble d'évaluation)

Les courbes de **TR** en fonction de N_p pour diverses valeurs de σ nous montrent que les meilleures valeurs de **TR = 87.33%** sont obtenus pour $\sigma = 0.00085$ et $N_p = 600$. Les paramètres σ et N_p influent sur **TR**, l'influence de N_p est plus importante. Nous remarquons une stabilité des courbes à partir de $N_p = 300$ paramètres. Au-delà de ces valeurs notre système se stabilise quelque soit les variations de σ et N_p .

Comparaison du taux de reconnaissance pour différents σ et différents N_p dans l'ensemble de test :




Fig. IV.9 Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble de test)

Nous avons les mêmes remarques que celle obtenues dans les expériences précédentes sur l'ensemble d'évaluation. Seulement, dans l'application sur la base de données test le **TR** atteint la valeur **TR = 97.5 %** pour $\sigma = 0.0004$ et $N_p = 600$.

Résolution (σ)	0.0004	0.0007	0.00085	0.0009	0.003	0.01
N_p	600	600	600	600	400	400
TR évaluation%	86.83	87	87.33	87.33	86.83	82.83
TR test%	97.5	97	96.5	96.5	95.5	94

Tab. IV.3 Taux de reconnaissance $N_p = 600$ et σ variable dans les deux ensembles.

Dans ce tableau nous constatons que le meilleur **TRtest= 97.5 %** avec résolution $\sigma = 0.0004$ et $N_p = 600$ c'est un bon résultat.




Fig IV.10: Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble d'évaluation)




Fig. IV.11 Taux de reconnaissance en fonction de N_p pour diverses σ (ensemble de test)

VI.7 Etude comparative

IV.7.1 Comparaison entre PCA et KPCA

(avec normalisation et classification par mesure de métrique)

PCA				KPCA				Nombre de paramètres
Ensemble évaluation	Ensemble évaluation			Ensemble évaluation	Ensemble évaluation			
TET%	TFR%	TFA%	TR%	TET%	TFR%	TFA%	TR%	N_p
14.11	14.16	14.06	85.9	10.16	10.16	10.17	89.92	10
13.85	13.83	13.88	86.2	8.39	8.33	8.46	91.7	100
13.99	14	13.99	86.01	8.49	8.50	8.49	91.51	400
14	14	14	86	7.67	7.66	7.68	92.33	500
14	14	14	86	6.49	6.5	6.49	93.51	600

Tab. IV .4 La comparaison entre PCA et KPCA [Haf 11].

D'après le **Tab. IV.7** nous constatons que le meilleur résultat de **TR** est obtenu pour la **KPCA**. Il est nettement mieux que le résultat donné par la **PCA** ; la courbe suivante illustre la différence entre les valeurs du **TEE** dans le cas de la **KPCA** et la **PCA** par rapport au nombre de paramètres caractéristiques **N_p**.




Fig.IV.12 Les courbes du **TEE** pour la **PCA** et la **KPCA** en fonction **N_p** [Haf 11].

Les courbes de la figure **Figure IV.19** montre le grand écart du taux d'égale erreur le **TEE**. Cet écart atteint **8.51%** ce qui est considérable dans le domaine de reconnaissance en biométrie.

IV.7.2 Comparaison entre le KPCA et la PCA avec différents de classification

		SVM		Distance		
		[Ben 10]	Nous	[Ben 10]	[Haf 11]	Nous
PCA(L ₁)	TFA%	2.7	/	6.72	13.83	/
	TFR%	2.09	/	6.39	13.88	/
	TR%	/	/	/	86.2	/
	TEE%	/	/	5.83	13.85	/
KPCA	TFA%	/	/	/	6.49	8.46
	TFR%	/	/	/	6.5	8.33
	TEE%	/	/	/	6.49	
	TR%	/	97.5	/	93.51(L ₄)	91.60(L ₂)

Tab. IV. 5. Comparaison entre le KPCA et PCA par différentes classifications

- **Rappel :** Rappelons que dans nos travaux nous utilisons les normes L₂ et L₃. Les meilleurs résultats sont obtenus dans le cas de la norme L₁.
- 1 Pour les résultats de PCA
- **Remarque :**

Les meilleurs résultats des travaux de M.A BENATIA [Ben 10] sur l'utilisation de l'ACP associé au calcul de métrique sont obtenus avec des TFA et TFR stables à partir de Np=10, et pour la distance L1. Dans le cas des travaux de HAFHOUF [Haf 11], les meilleurs TFR et TFA sont obtenus pour Np=100 et la distance L1. Donc, la meilleure norme dans les travaux c'est L1. Dans notre cas le meilleur TR est obtenu pour Np = 400 et la norme L₂.


IV.7.3 Pour les résultats de KPCA

Le meilleur **TR = 93.51% pour L_4** est obtenu pour $N_p=600$ et il est stable à partir de cette valeur [Haf 11]. Dans notre cas il est obtenu à partir de $N_p = 400$ et égale à **91.60 %** pour la norme L_2 . Nous pouvons affirmer que la KPCA est gourmande en nombre de paramètres, mais pour des performances du **SRV** bien meilleures. Notre méthode associée à la distance pourrait améliorer les performances.

Nous avons utilisé la **KPCA** avec une classification basée sur **SVM**. Le meilleur **TR** obtenu est **TR = 97.5 %** pour **$N_p = 600$** . L'ACP était associée au **SVM** dans un **SRV** et a donné un **TFA = 2.7 %** et **TFR = 2.09 %** dans [Ben 10]. Nous pouvons dire que la **KPCA** reste une méthode efficace et performante dans le **SRV** en biométrie et en l'associant au **SVM**, elle fait ses preuves et améliore nettement les performances du **SRV** telle était notre objectif.

IV.8 Conclusion

Nous pouvons dire que notre implémentation est fonctionnelle et les résultats obtenus sont satisfaisants. Nous avons étudié séparément la **KPCA** avec deux classifieurs différents : mesure de similarité et **SVM**. La **KPCA** est beaucoup plus efficace que la **PCA** et cela est bien prouvé dans **Tab. IV .7** et **Fig.IV.19**. La classification par **SVM** donne de meilleurs résultats que ceux obtenus par la mesure de similarité même en maintenant la **KPCA** comme méthode de réduction. Ce qui est évident, nous nous attendions à ce résultat car le **SVM** est jusqu'à maintenant irréprochable dans sa classification. Ceci dit le succès de l'approche réside dans l'utilisation de la **KPCA** à la base. Car d'après les résultats du **Tab. IV. 8** nous voyons bien que le **SVM** apporte énormément à l'amélioration des taux de performance du **SRV**. Mais l'apport de la **KPCA** est bien plus important.



***CONCLUSION
GENERALE***

Conclusion générale

L'identification biométrique consiste à identifier une personne au moyen de l'une de ses caractéristiques physiques : voix, empreintes digitales, visage, iris. Toutefois, un tel processus n'est pas infaillible et une personne mal intentionnée peut parvenir à contourner le processus d'identification. Afin de pallier un tel inconvénient, l'utilisation de plusieurs caractéristiques, appelées modalités a été proposée et développée dans de nombreux travaux. Le principe général est basé sur une prise de décision pour chaque modalité.

La classification est une étape très importante car elle permet de faciliter l'identification des individus qui est utilisée dans plusieurs domaines comme la médecine légale, la police scientifique, la sécurisation des comptes bancaires et la protection des bases de données à caractère confidentiel.

Notre objectif c'est une contribution modeste dans l'amélioration de la classification. Nous traitons cela du côté résolution des phénomènes non linéaires que peut rencontrer cette étape.

Dans notre travail nous utilisons une méthode basée sur l'analyse en composantes principales à noyau (**KPCA**) pour l'extraction de caractéristiques, réduction d'espace et aussi à la préparation à une classification non linéaire qui renforcera davantage la discrimination des classes qui est l'objectif de notre projet. La classification non linéaire est très sollicitée dans l'identification des personnes en biométrie. La confusion entre jumeaux, les personnes présentant une ressemblance extrême... sont difficiles à discriminer par le système de reconnaissance **SRV**. Car dans ces cas les classes peuvent être imbriquées ou bien l'intersection entre les deux ensembles peut être très grande. Dans un tel cas la **PCA** devient impuissante sur le plan discrimination malgré son optimalité concernant l'apport en information. La solution est de penser à rajouter un noyau (le **kernel**) pour pallier à cette insuffisance. Ce noyau dispose de plusieurs fonctions qui sont toutes non linéaires pour préparer à une classification discriminatoire. Dans notre travail la fonction **Gausséenne** du **Kernel** donne les meilleurs résultats pour cela elle est retenue et utilisée pour mettre à terme nos expériences et tests. L'algorithme de noyau PCA (**KPCA**) reste une des approches les plus fiables comme plateforme pour classification dans les SRV, offrant à la fois de bonnes performances pour l'extraction de caractéristique et un apport maximum en quantité d'information.

Notre système de reconnaissance de visage ainsi conçu repose sur une phase de prétraitement où le découpage de l'image et la conversion couleur RGB → NG sont réalisées. L'image est découpée par une fenêtre rectangulaire de taille 123x120 centrée autour des caractéristiques les plus stables liées aux yeux, aux sourcils au nez et à la bouche. Un filtrage par le filtre de Gabor bien sélectionné est utilisé. Puis l'image filtrée est soumise à la transformation **KPCA**. Enfin une classification par **SVM** est réalisée et une décision sur l'identification de la personne est prise. Elle sera ou accepter ou rejeter du système.

Au cours de ce travail, nous menons une étude comparative entre la **PCA** et le **KPCA** avec une classification de **SVM**. Le **SVM** a présenté ses preuves en classification ces

Conclusion générale

dernières années. C'est un algorithme très efficace et pratique. Pour toutes ces raisons nous l'avons choisi pour renforcer le pouvoir discriminant de la **KPCA**. Notre approche est implémentée en MATLAB 2009 et elle est appliquée et testée sur la base de données universelle la XM2VTS selon son protocole 1.

Les vecteurs descripteurs obtenus réalisent la BDD indexée. Il s'agit là de la phase d'enrôlement de notre système de reconnaissance de visages SRV. Une phase d'évaluation des paramètres est aussi réalisée sur une BDD évaluation. Finalement la stabilité de notre système est étudiée par son application à une BDD test.

L'étude comparative de la **PCA+Mesure de métriques**, **KPCA+ Mesure de métriques**, **PCA+SVM** et **KPCA+SVM** est détaillée dans le chapitre IV.

D'après les résultats obtenus l'application de KPCA avec SVM est bien meilleure que l'application de la KPCA associée au mesure de métriques le taux TR atteint la valeur **TR=97.5%** pour la classification par **SVM** contre un taux **TR = 93.51%** avec la classification par mesure de métrique avec un nombre de paramètres caractéristiques **Np =600**.

Parmi Les perspectives de notre travail nous pouvons citer:

- La fusion des différentes techniques d'extraction des caractéristiques,
- La combinaison entre l'information bidimensionnelle (image bidimensionnelle du visage) et l'information tridimensionnelle (image tridimensionnelle du visage) afin de rendre le système d'identification plus efficace,
- Utilisation d'autres modalités,
- Application à d'autres bases de données,
- Amélioration du prétraitement par adjonction d'autres filtres,
- Etude de l'extension de l'OC-SVM pour couvrir le cas multi classes sans passer par le SVM binaire utilisé dans la littérature.

Bibliographie

- [Adj 07] Adjout Mohamed et Benaissa Abdelhak, «Fusion de la DCT-PCA et la DCT-LDA appliquée à la reconnaissance de visages», Institut National de formation en Informatique (I.N.I) Oued-smar Alger, 2007.
- [Ahm 09] Ahmed Chaari, «Reconnaissance de visages par réseaux d'ondelettes de Gabor», Docteur de l'Université Lille, 2009.
- [AIS 11] AISSAOUI Azzedine et DJOUAMA Ala Eddine, «Détection de visage par la méthode SVM», Mémoire de Fin d'Etudes, en vue de la préparation du diplôme: MASTER, Département de Génie Electrique, Université Mohamed Khider Biskra, 2011.
- [Ale] Alexis Mignon et Frédéric Jurie «Reconnaissance de visages : une méthode originale combinant analyse discriminante logistique et distance sur graphe», GREYC-CNRS ENSICAEN, Université de Caen.
- [Ale 10] Alexis Mignon et Frédéric Jurie «Reconnaissance de visages : une méthode originale combinant analyse discriminante logistique et distance sur graphe», GREYC – CNRS, ENSICAEN, Université de Caen, 2010.
- [Atia2011] ATIA Amina, «Reconnaissance de visage pour l'authentification biométrique», Université Mohamed Khider BISKRA, 2011.
- [Badra 08] Bedra Salim et Mansoura Nabil, « Identification et authentification du visage en biométrie », Université Mohamed Khider BISKRA, 2008.
- [Bar 08] E. Barbeau, S. Joubert, O. Felician et eds.Solal, «Traitement et reconnaissance des visages : du percept à la personne», éditeur, Marseille, 2008.
- [Bed 08] Loubna BEDOUI «Authentification de visages par la methode d'analyse discriminante linéaire de Fischer» Université Mohamed Kheider de Biskra -Ingénieur d'état en Automatique,2008.
- [Bel 94] Belahcene Mébarka, «Analyse de texture par ACP»; Magister électricité industrie; Université de Batna; Octobre 1994
- [Benzaf 10] Achour AbdErrazak et Hachani Samia, « Reconnaissance biométrique par la méthode ICA », Université Mohamed Kheider de Biskra -Ingénieur d'état en électronique, 2010.
- [Ben 10] Benatia Mohamed Amine et KHENE Mohamed Walid; «Reconnaissance de visage en biométrie»; Université Mohamed Khider BISKRA;2010.
- [BES 00] Bessho H, Twai Y et Yachida M, «Detecting Human Face and Recognizing Facial Expressions using potential Net», Proceedings of the 15th International Conference on Pattern Recognition ICPR'2000, p. 387-397, Barcelona, 2000.
- [Bruce] Bruce A. Draper, «Recognizing Faces with PCA and ICA», Department of Computer Science Colorado State University Ft. Collins, CO 80523, U.S.A.

Bibliographie

- [DAI 98]** DAI D.Q., YUEN P. C. et FENG G. C, «A multi-resolution decomposition method for human face recognition», Proceedings, actes Vision Interface '98, p. 301-307, Vancouver, British Columbia, 1998.
- [Ete 96]** K. Etemad et R. Challapa, «Face recognition using discriminant eigenvectors», in proceedings of ICASSP, 1996
- [Fed 07]** Fedias Meriem, «L'apport de la couleur à la vérification d'identité à l'aide d'images de visage», Université Mohamed Kheider de Biskra, 2007.
- [Fra 02]** Francis R. Bach et Michael I. Jordan, «Kernel Independent Component Analysis», Journal of Machine Learning Research 3, p:4-8-9, 2002.
- [Fra 04]** Franck Davoine, Bouchra Abboud et Van Môm Dang, «Analyse de visages et d'expressions faciales par modèle actif d'apparence», Université de Technologie de Compiègne, France, 2004
- [Jou 06]** Reda Jourani, «Reconnaissance de visage», Université Mohammed V-Agdal de Rabat, 2006.
- [HAF 11]** Hafhouf Abdelouahab, Noui Souhila, «reconnaissance de visage par la méthode KPCA», Mémoire de Fin d'Etudes, en vue de la préparation du diplôme: MASTER, Département de Génie Electrique, Université Mohamed Khider Biskra, 2011.
- [HAM 09]** Nassim Hamitouche, et Zakaria Salmi, « Système d'identification biométrique de personnes par reconnaissance de l'iris », Ecole nationale Supérieure d'Informatique (ESI) Oued-Smar, Alger, 2009.
- [Her]** Hervé Le Borgne et Anne Guérin-Dugué, «Caractérisation d'images par analyse en composantes indépendantes», L.I.S – I.N.P.G.46 avenue Félix Viallet F-38000 Grenoble Cedex.
- [Gui 11]** Gui-Fu Lu et Jian Zou, «Feature Extraction Using a Complete Kernel Extension of Supervised Graph Embedding», 2011.
- [Kre 05]** Kresimir Delac, Mislav Grgic et Sonja Grgic, «Generalization Abilities of Appearance-Based Subspace Face Recognition Algorithms», 2005.
- [Lau 05]** Laurent Zwald, «Performances statistiques d'algorithmes d'apprentissage: 'Kernel projection machine' et analyse en composantes principales à noyau»; Université PARIS XI; p(14,15,16), 2005.
- [Lor 07]** Lorenzo Torresani et Kuang C. Lee. «Large margin component analysis », Advances in Neural Information Processing Systems 19, pages 1385–1392. MIT Press, Cambridge, MA, 2007.
- [Moa]** Moad Benkiniouar et Mohamed Benmohamed, «Méthodes d'identification et de reconnaissance de visages en temps réel basées sur AdaBoost»

Bibliographie

- [**Moh 02**] Mohamed Tayeb Laskri et Djallel Chefrour , «Who_Is : système d'identification des visages humains» Département d'Informatique ,Université Badji Mokhtar Annaba,2002.
- [**Moh 08**] Mourad Abbas, «Identification de thèmes pour la reconnaissance automatique de la parole», Ecole Nationale Supérieure Polytechnique, 2008.
- [**Nad 04**] Nedjem Eddine Ayat, «Sélection de modèle automatique des machines à vecteurs de support: application à la reconnaissance d'images de chiffres manuscrits.», École de Technologie Supérieure université Du Québec, 2004, p : 45
- [**Ned 04**] Nedjem Eddine Ayat, «Sélection de modèle automatique des machines à vecteurs de support: application à la reconnaissance d'images de chiffres manuscrits.», École de Technologie Supérieure université Du Québec, 2004, p : 46-47
- [**Nic 09**] Nicolas MORIZET, «Reconnaissance biométrique par fusion Multimodale du visage et de l'Iris», Paris, le 18 mars 2009.
- [**Oli 08**] Olivier Delalleau, «Extraction hiérarchique de caractéristiques pour l'apprentissage à partir de données complexes en haute dimension», Examen Pré-doctoral, 2008.
- [**Oua 09**] Ouamane Abdelmalik et Mehdaoui Abdelghaffar, «identification et authentification des visages en biométrie», Mémoire de Fin d'Etudes, en vue de la préparation du diplôme: INGENIEUR, Département de Génie Electrique, Université Mohamed Keider Biskra, 2009.
- [**Oua 11**] Ouamane AbdElmalik, «Etude de la fusion de modalités pour l'authentification en biométrie (visage, voix)», Mémoire de Fin d'Etudes, en vue de la préparation du diplôme: MAGISTER, Département de Génie Electrique Université Mohamed Keider Biskra, 2011.
- [**Ouh 11**]Ouhabab Asma, «Système Biométrique pour l'Identification par Visage», Université Mohamed Khider BISKRA, 2011.
- [**pal**] S. palanivel, B. S. Venkatesh et B. Yegnamarayana, «Real time face recognition system using auto associative neural network models, Speech and vision», laboratory Dpt of computer science and engineering, Indian institute of technology madras, India
- [**PAS 06**] Pascal Barbedor, «Analyse en composantes indépendantes par ondelettes», Université Paris 7 Denis Diderot, UFR de Mathématiques Doctorat Spécialité mathématiques, 5 décembre 2006.
- [**Pra 05**] Prahlad R. Enuganti; «Face Recognition using Tensor Analysis», The University of Texas at Austin, Literature Survey, EE381K – 14 Multidimensional Digital Signal Processing, March 25, 2005
- [**Rab**] L.R. Rabiner: Atutorial on hidden markov model and selected applications in speech recognition

Bibliographie

[Rao 11] Alismail Mohamed Raouf et Ourchani NorElhouda, «Fuion multimodale des scores pour la reconnaissance des personnes», Mémoire de Fin d'Etudes, en vue de la préparation du diplôme: MASTER, Département de Génie Electrique, Université Mohamed Khider Biskra, 2011.

[Rap] Raphael Cendrillon et Brian C. Lovell, «Real -time Face recognition using Eigenfaces», Dpt of computer Science and Electrical Engineering University of Queensland, Australia.

[Ric]Richard, Fahed Abdallah, «Algorithme d'apprentissage séquentiel pour la méthode KFDRelations avec la méthode KPCA», Laboratoire de Modélisation et Sûreté des Systèmes, Université de Technologie de Troyes, France.

[Ric 04] Richard Lepage, «Reconnaissance d'algue toxiques par vision artificielle et réseau de neurones», mémoire de recherche, université du québec à Rimouski, 2004.

[Sai 05]D. Saigaan Benoudjtk et Benmahameds Lelandais, «Authentification D'individus Par Reconnaissance De Visages », 2005.

[Sam 93] F. Samaria, «Face segmentation for identification using hidden markov models», in british machine vision conference, 1993.

[SAM 94] F. S. Samaria et Harter A. C, « Parameterization of a stochastic model for human face identification», IEEE Comput. Soc. Press, p. 138-180, 1994.

[Sci NT] ScienceDirect- Neurocomputation Two-dimensional direct and weighted linear discriminant analysis for face recognition.mht.

[Sci PR] ScienceDirect - Pattern Recognition Making FLDA applicable to face recognition with one sample per person.mht.

[SHE 00] SEHAD A, HOCINI H, HADID A, DJEDDI M et AMEUR S, «Face recognition under varying views», Actes du 5e Colloque Africain sur la Recherche en Informatique CARI'2000 (INRIA), p. 375-382 Antananarivo, Madagascar, 2000.

[Sid 11] Mébarka Belahcene, AbdElMalik Ouamane, Mohamed Boumehrez et AbdElHamid Benakcha, «Authentification de visages par les transformations de Hough et Gabor associées à EFM et SVM pour la classification», Intelligence artificielle, Université MUNDIAPOLIS Casablanca, 2011.

[Suj 12] Sujet XX - Reconnaissance de Visage.

<http://www.cmap.polytechnique.fr/~peyre/cours/x2005signal/13:07,12/04/2012>.

[TUR 91] Turk M. A et Pentland A. P, «Face recognition using eigenfaces», IEEE Comput. Sco. Press, p. 586-591, June 1991.

[VAL 94] Valentin D. et Abdi H, «Modèles neuronaux, connexionnistes et numériques de la reconnaissance des visages», It Psychologie française, 39(4), p. 357-392, 1994.

Bibliographie

[**Xié 04**] «Xièmes rencontres de la Société francophone de classification», Bordeaux, France, 2004.

[**Xue 02**] Xue-wen Chen, Thomas Huang, « Facial expression recognition: A clustering-based approach», University of Illinois at Urbana-Champaign, USA, 2002.

[**Yan 05**] Jian Yang, Alejandro F. Frangi, Jing-yu Yang, David Zhang, Senior Member et Zhong Jin, «KPCA Plus LDA: A Complete Kernel Fisher Discriminant Framework for Feature Extraction and Recognition», 2005.

[**YANG 98**] Yang M.H., Ahuja N., Kriegman D., «Detecting Human Faces in Color Images», Proceedings of the 1998 IEEE International Conference on Image Processing (ICIP 98), pp.127-139, Chicago, 1998.

[**YANG 99**] Yang M.H., Ahuja N et Kriegman D «Face Detection Using a Mixture of Factor Analyzers», Proceedings of the 1999 IEEE International Conference on Image Processing (ICIP 99), Kobe, Japan, 1999.

[**You 08**] Young-Gil Kima, Young-Jun Song, Un-Dong Chang, Dong-Woo Kimb, Tae-Sung Yun et Jae-Hyeong Ahn, «Face recognition using a fusion method based on bidirectional 2DPCA», 2008.

[**Zho 04**] Zhong-Qiu Zhao , De-Shuang Huang et Bing-Yu Sun, «Human face recognition based on multi-features using neural networks committee », Hefei Institute of Intelligent Machines, Chinese Academy of Sciences, P.O. Box 1130, Hefei, Anhui 230031, China, 2004.

[**Zha 03**] W. Zhao, R. Chellapa, P. J. Phillips et A. Rosenfeld, «Face Recognition: A Literature Survey», ACM Computing Surveys, Vol. 35, No. 4, pp. 399–458, 2003.

[**34**]Memoire Online Algorithmes d'apprentissage pour la classification de documents
yasmine Hanane zeggane Mokhtar

http://www.memoireonline.com/02/11/4274/m_Authentification-de-visages-par-la-methode-analyse-discriminante-lineaire-de-Fischer5.html13:31,12/04/2012

I. Les fonctions noyaux

Quelques exemples de fonctions noyaux :

- **Linéaire** : $k(x, x') = x \cdot x'$
- **Polynomial** : $k(x, x') = (x \cdot x')^d$ ou $k(x, x') = (c + x \cdot x')^d$
- **Gaussien** : $k(x, x') = e^{-|x-x'|^2/\sigma^2}$
- **Laplacien** : $k(x, x') = e^{-d|x-x'|/\sigma^2}$ Où $d(x-x')$ est une distance, par exemple distance χ^2

Le noyau peut être composé de plusieurs noyaux pour obtenir un noyau plus robuste.
par exemple : $k(x, x') = \sum \alpha_i k_i(x, x')$

II. Types de classification

Plusieurs techniques de classification ont été proposées dans la littérature. Ces méthodes peuvent être subdivisées en deux catégories qui sont la classification supervisée et non supervisée selon les résultats qu'on veut obtenir et la nature des données.

II.1 Classification supervisée

La classification est dite supervisée car on dispose d'exemples déjà étiquetés (étiquetés par une classe). Son but principal est de trouver, à partir des exemples déjà classés (appelé ensemble d'apprentissage), un modèle afin de prédire les classes de nouvelles données.

II.2 Classification non supervisée

Contrairement à la classification supervisée, la classification non supervisée ne dispose pas d'un ensemble d'apprentissage. De ce fait, cette dernière cherche à diviser et à classer un ensemble de données de sorte que les classes soient les plus homogènes possibles.

Il existe deux types de méthode de constitution des groupes (classification non supervisée) :

II.2.1 Classification hiérarchique

Pour un niveau de précision donné, deux individus peuvent être confondus dans un même groupe, alors qu'à un niveau de précision plus élevé, ils seront distingués et appartiendront à deux sous-groupes différents. Le résultat d'une classification hiérarchique n'est pas une partition de l'ensemble des individus.

ANNEXE

Elle Consiste à établir une structure arborescente ascendante (à partir de chaque individu de groupe différent en constituant des groupes de plus en plus gros) ou descendante (à partir de tous les individus regroupés) On distingue deux types de classification hiérarchique, qui sont la classification ascendante et la classification descendante:

- **La classification agglomérative (ou ascendante)**

La classification ascendante hiérarchique (CAH) conduit à la construction d'un arbre de classification (ou dendrogramme) montrant le passage des n individus au groupe « total » par une succession de regroupements.

Cette méthode part d'un grand nombre de classes, à chaque étape de l'algorithme on associe les deux classes les plus similaires. On réitère l'algorithme jusqu'à l'obtention d'une classe mère (classe qui regroupe l'ensemble des classes).

- **La classification divisive (ou descendante)**

La classification descendante hiérarchique procède à l'inverse par subdivisions successives de l'ensemble à classer.

À partir de la classe mère (l'ensemble des données), une classe sera subdivisée à chaque étape jusqu'à l'obtention d'un ensemble de classes atomiques (une classe par ensemble des donnée similaire).

II.2.2 Classification partitionnelle

Les classifications non hiérarchiques ou partitionnelles, aboutissant à la décomposition de l'ensemble de tous les individus en m ensembles disjoints ou classes d'équivalence.

Le résultat obtenu est alors une partition de l'ensemble des individus, un ensemble de parties, ou classes de l'ensemble I des individus telles que :

- toute classe soit non vide
- deux classes distinctes sont disjointes
- tout individu appartient à une classe.

La hiérarchie n'est pas présentée dans ce type de classification. Les algorithmes de ce type produisent des classes mais sans former de hiérarchie (toute les classes sont créer dans un même niveau)