

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



DÉPARTEMENT D'ÉLECTRONIQUE

Projet de fin d'études

En vue de l'obtention du diplôme de Master en Electronique

Thème :

**Utilisation de l'analyse discriminante linéaire
pour un système biométrique FKP**

Encadré par :

Mme L.Hamami

Réalisé par :

Mlle Razika BOUZAR

Promotion : juin 2013

ملخص :

مع التطور التكنولوجي الكبير الذي يشهده عصرنا الحالي عرف المجال البيومتري تطورا كبيرا من ناحية كفاءة وفعالية الانظمة او من ناحية التقنيات البيومترية المستعملة ، ونتطرق في هذه المذكرة إلى دراسة احدى هذه التقنيات البيومترية الحديثة ألا وهي (FKP) التي تعتمد على دراسة بصمة مفصل الاصبع ، ولتقييم فعالية هذه التقنية قمنا بتطبيق خوارزمية (LDA) لاستخلاص خصائص صور بصمات المفصل. وقد تمت محاكاة هذه الدراسة في برنامج MATLAB.

الكلمات المفتاحية : صور ، بصمة مفصل الاصبع ، MATLAB ، LDA

Résumé :

Avec le développement technologique, le domaine de la biométrie a connu un grand essor que ce soit au niveau des performances des systèmes ou des techniques biométriques. Dans ce travail, on va étudier une des techniques biométriques récentes, la «FKP » qui consiste à différencier entre les personnes en se basant sur les empreintes de l'articulation du doigt. Pour évaluer cette technique nous avons appliqué l'algorithme LDA pour l'extraction des caractéristiques des images FKP. Cette étude a été simulée sur MATLAB.

Mots clés : images, empreinte de l'articulation du doigt, MATLAB, LDA

Abstract:

Due to the development of science and technology nowadays, the biometric field has known a great evolution in both system performance and biometric techniques. In this project, we are going to deal with one of the recent techniques which is called the (FKP: Finger Knuckle Print) that identifies people based on their knuckle print. To evaluate the precision of its performance, we had applied LDA algorithm to extract the features of the FKB images, this study was simulated on MATLAB program.

Key words: images, Finger Knuckle Print, MATLAB, LDA

Table des matières

1.	INTRODUCTION	2
2.	LES METHODES DE RECONNAISSANCE GLOBALES	2
2.1.	Analyse en composantes principales (PCA).....	4
2.2.	Analyse Discriminante Linéaire (LDA)	5
3.	SIMULATION EN MATLAB DE L'ALGORITHME LDA.....	6
3.1.	Principe de la LDA	7
3.2.	Conception du système de reconnaissance	8
3.3.	Présentation de la base de données utilisée	10
3.4.	Évaluation des performances.....	10
3.4.1.	Taux de fausse acceptation FAR et taux de faux rejet.....	11
3.4.2.	Taux d'identification.....	12
4.	CONCLUSION.....	13
	Bibliographie	13

1. INTRODUCTION

La biométrie, qui est la discipline permettant de reconnaître l'identité d'une personne à partir de ses caractéristiques physiologiques ou comportementales, a attiré et attire encore plus l'attention dans la dernière décennie à cause de l'accroissement du besoin sécuritaire dans plusieurs domaines et en raison de ses nombreuses applications qui offrent plusieurs avantages par rapport aux techniques classiques de reconnaissance comme les clés, les mots de passe, les cartes, etc. qui sont exposés au vol, à la perte ou à la falsification.

De nos jours et avec le développement technologique, plusieurs techniques biométriques ont été découvertes ou utilisées comme : l'iris, la voix, le visage, la dynamique de frappe de claviers, l'ADNetc.

L'extraction de caractéristiques est une phase importante cruciale dans un système biométrique. Cette dernière doit être différente d'une personne à une autre et invariante pour les images d'une même personne. La définition d'une signature est un problème très complexe, du fait que les images d'une même personne peuvent être différentes en fonction des différentes conditions de prise de vue.

Dans la bibliothèque scientifique, les méthodes d'extraction de signatures regroupent en deux grandes familles : les méthodes locales et les méthodes globales.

Dans ce travail, on va utiliser une des méthodes statistiques (ou globales) de reconnaissance qui est la LDA « Linear Discriminant Analysis » comme module d'extraction de caractéristiques dans un système biométrique basé sur une des modalités récentes dans la biométrie qui est la FKP « Finger-Knuckle-Print ».

2. LES METHODES DE RECONNAISSANCE GLOBALES

Ces méthodes traitent l'image dans son intégralité sans tenir compte des caractéristiques locales. Elles sont généralement basées sur des techniques statistiques bien connues. La matrice constituant l'image est injectée à l'entrée du système de reconnaissance et sera convertie à un ensemble de vecteurs, afin de faciliter les traitements. Ces méthodes sont rapides à mettre en œuvres et les calculs de bases sont de complexité moyenne.

Nous pouvons distinguer deux types de techniques parmi les méthodes globales : les *techniques linéaires* et les *techniques non linéaires*.

Les techniques linéaires projettent linéairement les données d'un espace de grande dimension (par exemple, l'espace de l'image originale) sur un sous-espace de dimension inférieure. Malheureusement, ces techniques sont incapables de préserver les variations non convexes des *variétés* (géométriques donc au sens mathématique du terme) des images afin de différencier des individus. Dans un sous-espace linéaire, les distances euclidiennes et plus généralement les distances de Mahalanobis, qui sont normalement utilisées pour faire comparer des vecteurs de données, ne permettent pas une bonne classification entre les classes des individus. Ce facteur crucial limite le pouvoir des techniques linéaires pour obtenir une détection et une reconnaissance très précises.

La technique linéaire la plus connue et sans aucun doute l'analyse en composantes principales (PCA), également appelée *transformée de Karhunen-Loeve*.

Cependant, le PCA classique nécessite que les images soient mises sous formes de vecteurs, ce qui a pour effet de détruire la structure géométrique de l'image.

Pour ne pas perdre les informations de voisinage lors du passage de l'image en vecteur, une méthode PCA bi-dimensionnelle (2-D PCA) a été étudiée. Cette méthode prend en entrée des images et non plus des vecteurs.

Il existe d'autres techniques également construites à partir de *décompositions linéaires* comme l'analyse discriminante linéaire (LDA), ou encore l'analyse en composantes indépendantes (ICA).

Tandis que le PCA est plus adaptée pour la reconstruction d'image mais elle ne considère pas la séparabilité des différentes classes. Pour une séparabilité optimale, l'algorithme LDA construit un sous-espace discriminant pour distinguer de façon optimale les visages de différentes personnes. Elle permet donc d'effectuer une véritable séparation de classes.

L'algorithme ICA, quant à lui, est une généralisation de l'algorithme PCA avec lequel il coïncide dans le cas de données gaussiennes. L'algorithme ICA est basé sur le concept intuitif de *contraste* et permet d'éliminer la redondance statistique des données de départ.

Bien que ces méthodes globales linéaires basées sur l'apparence évitent l'instabilité des toutes premières méthodes géométriques qui ont été mises au point, elles ne sont pas assez précises pour décrire les subtilités des variétés (géométriques) présentes dans l'espace de l'image originale. Ceci est dû à leurs limitations à gérer la non-linéarité.

Afin de pouvoir traiter ce problème de non-linéarité en reconnaissance, de telles méthodes linéaires ont été étendues à des techniques non linéaires basées sur la notion mathématique du noyau ("*kernel*"). 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. Bien que les méthodes basées sur le noyau peuvent atteindre une bonne performance sur les données d'entraînement, il ne peut pas en être de même pour de nouvelles données en raison de leur plus grande flexibilité ; contrairement aux méthodes linéaires.

Voici deux techniques qui appartiennent à cette famille et qui ont été appliquées pour la reconnaissance des images FKP :

2.1. Analyse en composantes principales (PCA)

Cette méthode a été utilisée, pour la première fois, dans la reconnaissance automatique de visage en 1991 par MA. Turk et AP. Pentland au MIT Media Lab. Elle est aussi connue sous le nom Eigenface. Dans cette approche, chaque image de l'ensemble d'apprentissage est représentée par un ensemble de coefficients (poids) arrangés sous forme de vecteur. Les poids sont les coefficients de projection de l'image de visage sur l'espace engendré par les images propres, d'où le nom Eigenface. Pour la phase de l'apprentissage, chaque vecteur contenant les poids représentant un visage est stocké dans la base de données [1].

Lors de la reconnaissance, l'image de teste est représentée, elle aussi, par son vecteur de poids. L'identification consiste à trouver, dans la base de données, l'image dont les poids sont les plus proches, en terme de distance (par exemple la distance euclidienne), des poids de l'image de teste.

Les images propres sont les composantes principales de la distribution des images constituant l'ensemble d'apprentissage. Elles sont obtenues en calculant les vecteurs propres de la matrice de covariance formée par toutes les images de l'ensemble d'apprentissage. Le

nombre total des images propres est égales aux nombre des images de l'ensemble d'apprentissage. Néanmoins, seulement les images propres les plus significatives (ayant les plus grandes valeurs propres) sont prises en compte, les autres sont négligées [1].

Cette méthode utilise le niveau de gris des pixels de l'image et elle est facile à mettre en œuvre, néanmoins, elle est très sensible aux variations d'éclairage, de pose et de capture de l'image. Le principe selon lequel on peut construire un sous-espace vectoriel en ne retenant quelles « meilleurs » vecteurs propres, tout en conservant beaucoup d'information utile, fait du PCA un algorithme efficace et couramment utilisé en réduction de dimensionnalité.

2.2. Analyse Discriminante Linéaire (LDA)

L'algorithme LDA est né des travaux de Belhumeur et al. de la Yale Université (USA), en 1997. Il est aussi connu sous le nom de Fisherfaces. Contrairement à la PCA qui ne tient pas compte des différences entre les classes, l'algorithme LDA assure une véritable séparation des classes. Pour l'utiliser, il faut donc au préalable organiser l'ensemble des images d'apprentissage en plusieurs classes. Chaque personne est représentée par une classe qui contient toutes ses images [2].

Pour utiliser cet algorithme, les images de l'ensemble d'apprentissage sont converties en vecteurs afin de faciliter leur manipulation. A partir de ces vecteurs, on calcule l'image moyenne (le vecteur moyen) de chaque classe et l'image moyenne de toutes les images de l'ensemble d'apprentissage. Les images de chaque classe sont centrées par rapport à la moyenne de la classe et les matrices de dispersion intra-classe (la dispersion entre les images appartenant à une classe et l'image moyenne de cette classe) et de dispersion inter-classe (la dispersion entre l'image moyenne de chaque classe et l'image moyenne de l'ensemble d'apprentissage) sont calculées. Par la suite, ces matrices seront utilisées pour trouver la base qui assure la projection la plus optimale de façon à maximiser la dispersion inter-classe tout en minimisant la dispersion intra-classe. Chaque classe sera alors représentée par les coefficients de sa projection sur la base trouvée.




Figure 2.1 Illustration du principe de séparation optimale des classes par le LDA. Trois distributions 3D sont projetées sur deux sous-espaces 2D décrits par les vecteurs W_1 et W_2 . Puisque le LDA essaye de trouver la plus grande séparation parmi les classes, on voit bien que W_1 est ici le vecteur optimal

L'image de test, convertie en vecteur, est projetée sur la base trouvée lors de l'apprentissage. La distance entre les coefficients de projection de l'image test et ceux des images de l'ensemble d'apprentissage est calculée. L'image test appartiendra alors à la classe dont la distance calculée est minimale par rapport aux autres classes.

Cet algorithme est très utilisé dans la reconnaissance car il assure une véritable séparation entre les classes, en minimisant les variations entre les images d'un même individu (variations intra-classe) tout en maximisant les variations entre les images d'individus différents (variations inter-classes) [2].

3. SIMULATION EN MATLAB DE L'ALGORITHME LDA

Comme on a expliqué avant, L'analyse discriminante linéaire est une méthode statistique qui étudie des données provenant de groupes connus a priori appelés classes. L'idée de base de cette analyse est de trouver la transformation linéaire permettant d'assurer la meilleure séparation possible de ces classes.

L'analyse discriminante linéaire a fourni de bons résultats dans plusieurs domaines, dont la reconnaissance de la parole et celle de visages. Contrairement à l'analyse en composantes principales qui encode l'information dans un espace orthogonal linéaire, la LDA

encode l'information discriminatoire dans un espace linéaire séparable dont la base n'est pas nécessairement orthogonale.

Dans cette section, on verra l'algorithme de l'analyse discriminante linéaire utilisés dans la reconnaissance des images FKP tout en expliquant son principe. Là aussi, on ne s'intéressera qu'à la phase d'extraction des caractéristiques des images de la base de données. La programmation et la simulation de cet algorithme ont été faites par la suite avec le logiciel de calcul matriciel Matlab.

3.1. Principe de la LDA

Dans le but d'assurer une très bonne séparation des données appartenant à des classes différentes, l'algorithme LDA cherche à trouver la projection optimale W_{opt} permettant de maximiser le rapport de la dispersion inter-classes S_b contre la dispersion intra-classes S_w , c'est ce qu'on appelle le critère de Fisher. Cela revient à maximiser les variances des données appartenant à des classes différentes tout en minimisant les variances des données appartenant à la même classe.

$$W_{opt} = \underset{W}{\operatorname{argmax}} \frac{W S_b W^T}{W S_w W^T} = [W_1 W_2 \dots W_k] \quad (3.1)$$

S_b : La matrice de dispersion inter – classes

S_w : La matrice de dispersion intra – classes

Les colonnes $W_1 W_2 \dots W_k$ de W_{opt} représentent les vecteurs propres généralisés de S_b et S_w associés aux valeurs propres généralisées décroissantes $\lambda_1, \lambda_2, \dots, \lambda_m$ C'est-à-dire :

$$S_b W_i = \lambda_i S_w W_i \quad i = 1, \dots, k$$

On peut donc trouver la matrice W_{opt} en trouvant les vecteurs propres de la matrice $S_w^{-1} S_b$ Car en multipliant l'équation précédente par S_w^{-1} on aura :

$$S_w^{-1} S_b W_i = S_w^{-1} \lambda_i S_w W_i \quad (3.2)$$

Ce qui est équivalent à :

$$(S_w^{-1} S_b) W_i = \lambda_i W_i$$

On voit bien que sont les vecteurs propres de la matrice.

3.2. Conception du système de reconnaissance

Notre système biométrique basé sur les caractéristiques des images FKP, extraites par la méthode globale LDA, comporte deux phases essentielles: le module d'apprentissage et celui de reconnaissance :

Par analogie, la phase d'apprentissage correspondrait à un enrôlement réel de personnes qui seraient enregistrées dans une base de données. Cette phase consiste donc à récolter une grande quantité d'images FKP afin de se constituer une base de données de départ. Dans notre cas, Nous avons ainsi utilisé la base de données « Poly-U Finger-Knuckle-Print » pour évaluer les performances de cette méthode.

Il est nécessaire de construire un système de coordonnées locales pour chaque image FKP. Après avoir fait un tel système de coordonnées, une région d'intérêt (ROI) peut être recadrée de l'image originale pour l'extraction des caractéristiques.

Dans un premier temps, on construit une matrice pour chaque personne contenant M images de la région d'intérêt de la base d'apprentissage converties en vecteurs. Les images sont ensuite normalisées. Puis l'image moyenne est calculée. On réajuste ensuite les données par rapport à la moyenne. On applique alors l'algorithme de la LDA à ces matrices réajustées. La chose à retenir est que ces algorithmes fournissent en sortie ce que l'on appelle une matrice de projection W qui va nous être très utile dans la seconde partie de la phase d'apprentissage.

Elle consiste à la projection des images apprises (normalisées et réajustées par rapport à la moyenne) sur un espace vectoriel dont les vecteurs sont les éléments de notre matrice de projection W . Toutes ces projections sont finalement stockées dans une grande base de données.

Passons maintenant à la phase de reconnaissance. Lorsqu'une nouvelle image de la base de Test est mise devant le système, elle est normalisée et l'image moyenne de la base d'apprentissage lui est retirée. On la projette ensuite sur l'espace vectoriel relatif à la matrice de projection W afin de comparer avec toutes les projections issues de la phase d'apprentissage et qui étaient stockées dans la base de données. Par le terme comparer, il faut

comprendre effectuer un calcul de distance entre les projections vectorielles. On a utilisé la distance euclidienne comme règle de décision, en mesurant la distance euclidienne entre l'échantillon qu'on veut tester et celui (ceux) dans la base de données. Si cette distance est petite (par rapport à un seuil bien précis), on dit que ces deux projections sont similaires. Ainsi, le résultat de la reconnaissance est l'image de la base d'apprentissage qui ressemble le plus à la nouvelle image présentée au système dans le cas du mode d'identification et un résultat d'acceptation ou de rejet dans le cas du mode de vérification.

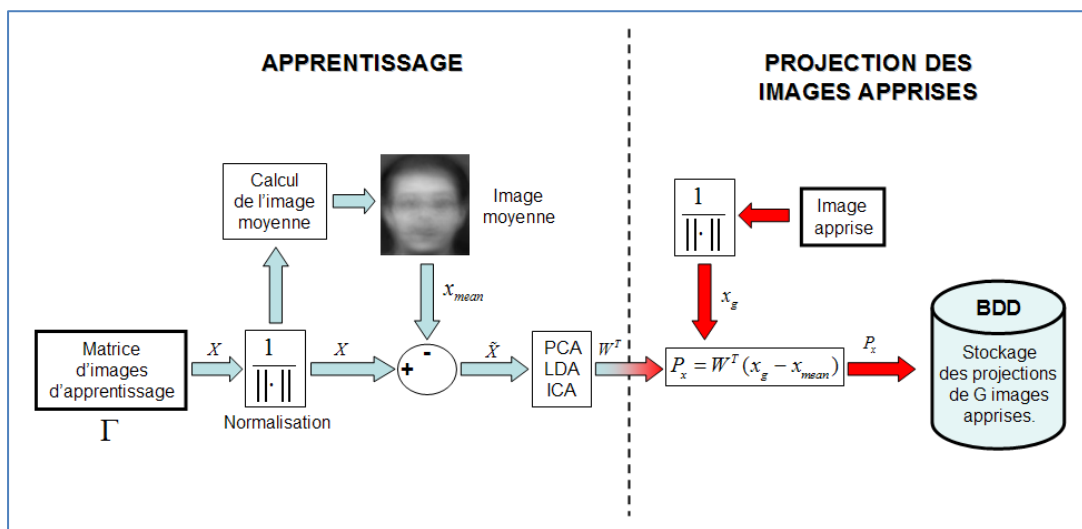


Figure 3.1 Phase d'apprentissage d'un système de reconnaissance utilisant une méthode globale

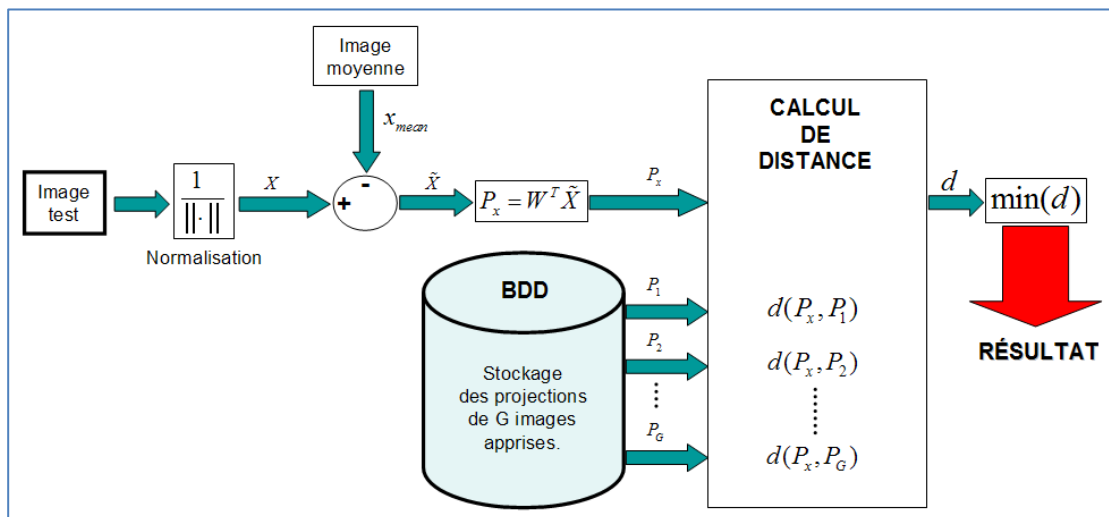


Figure 3.2 Phase de reconnaissance d'un système de reconnaissance faciale utilisant une méthode globale

3.3. Présentation de la base de données utilisée

Notre expérience a été faite sur des images de la base de données PolyU [3]. La base de données utilisée est scindée en deux ensembles : ensemble d'apprentissage, ensemble de test. L'ensemble d'apprentissage est utilisé comme ensemble de référence, il contient 4 images du doigt « majeur droit » pour 30 personnes. Il sert d'ensemble de base. L'ensemble de test permet de tester le système en utilisant 2 images de test pour chacun des quatre doigts pour 45 personnes. L'ensemble de test est divisé en deux classes : clients (30 personnes) et imposteurs (15 personnes).

3.4. Évaluation des performances

Pour déterminer les performances du système de reconnaissance des images FKP se basant sur l'algorithme vu précédemment (LDA), plusieurs paramètres doivent être déterminés, comme :

FAR : le taux de fausses acceptations, c'est le nombre des imposteurs acceptés par le système sur le nombre total d'imposteurs.

FRR : le taux de faux rejets, c'est le nombre de clients légitimes refusés par le système sur le nombre total de clients légitimes.

ERR : le taux d'égale erreur qui est le point d'intersection entre le FAR et le FRR.

Taux d'identifications correctes (le taux de reconnaissance): le pourcentage des reconnaissances justes, c'est le nombre des tests correspondant à une identification correcte sur le nombre total de tests effectués.

On va commencer cette section par une présentation des résultats obtenus pour les taux de reconnaissance FAR, FFR pour différents seuil afin de tracer la courbe ROC (les taux de fausses acceptations (FAR) et de faux rejets (FRR) en fonction du seuil de décision) en déterminant ainsi l'ERR. Par la suite on exposera le taux d'identification correcte obtenu.

3.4.1. *Taux de fausse acceptation FAR et taux de faux rejet*

Pour mesurer le taux de fausses acceptations, on injecte au système de reconnaissance, des images de visage de personnes inconnues. Ce qui mène à enlever certaines personnes de la base de données lors de la phase de l'apprentissage pour pouvoir les utiliser lors des tests.

Ces personnes sont appelées imposteurs. Pour ce qui est du taux de faux rejets, on injecte au système de reconnaissance, des images de visage de personnes connues, c'est-à-dire, les images de tests doivent appartenir aux personnes présentes dans l'ensemble d'apprentissage.

Ces personnes sont appelées clients. La mesure de FAR et FRR se fait en fonction d'un seuil de décision. Le seuil de décision permet au système d'accepter ou de rejeter une personne. Soit S ce seuil de décision; lors de la reconnaissance quand la distance minimale d entre l'image de test et celles de la base de données est déterminée, elle sera comparée à ce seuil S . Si d est inférieure à S , la personne sera acceptée et dans le cas contraire elle sera rejetée. Dans un système biométrique, on cherche toujours le seuil optimal permettant de donner $FAR=FRR$, dans le but d'équilibrer les erreurs dues aux fausses acceptations et aux faux rejets. Car, si le FAR est grand, le nombre d'imposteurs acceptés par le système sera élevé. Dans le cas où c'est le FRR qui est grand on aura un nombre élevé de clients rejetés par le système. On a procédé à deux expériences pour cela.

Le tableau ci-dessus résume les différents résultats obtenus lors de la recherche du seuil idéal donnant un $FRR = FAR$.

Le Tableau 3.1 montre que le choix du seuil n'est pas une chose très facile, car si le seuil est très faible, on rejettera plusieurs utilisateurs légitimes ; même si on choisit un seuil élevé on aura un autre problème qui est l'acceptation de plusieurs imposteurs, la solution idéale est d'essayer d'avoir un seuil qui donne un $FAR = FRR$. En se basant sur la courbe ROC (figure 3.4), l'EER obtenu pour cette méthode « LDA » est de **28**.

Tableau 3.1 Mesure du FAR et du FFR

Seuil	0.001	0.005	0.010	0.020	0.030	0.040	0.050
FAR	0.049	0.12	0.2	0.35	0.5	0.75	0.78
FFR	0.480	0.45	0.39	0.33	0.24	0.20	0.18

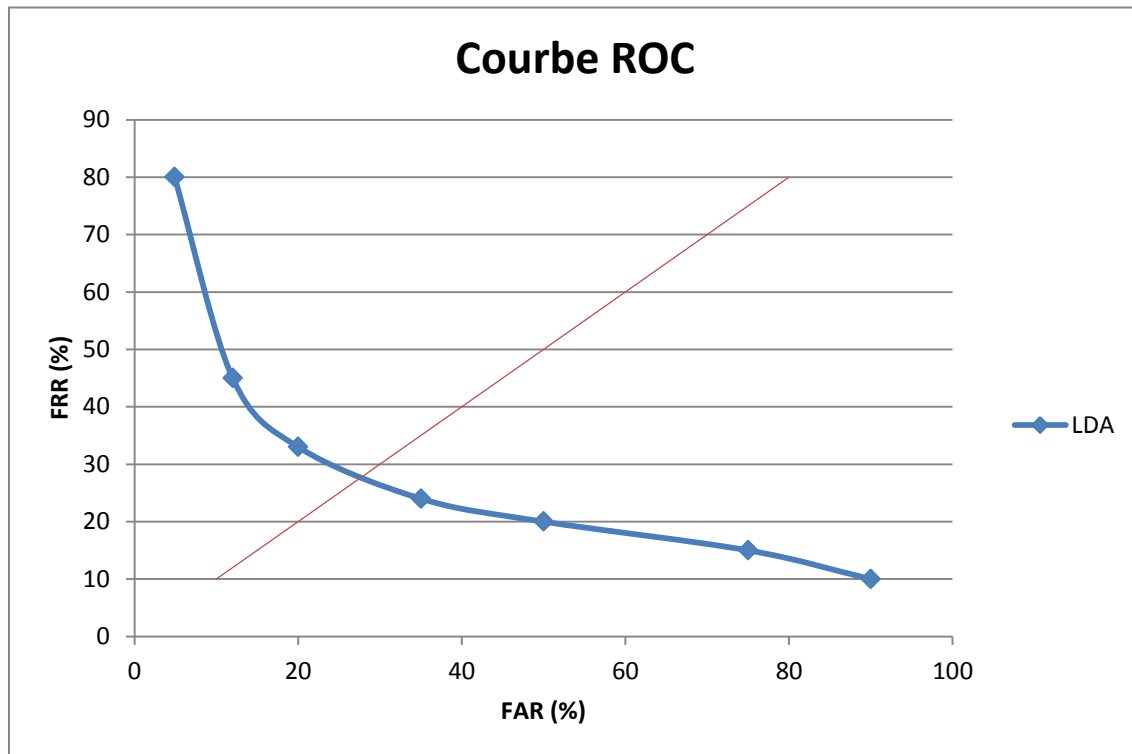


Figure 3.3 Courbe ROC « LDA : Linear Discriminant Analysis »

3.4.2. Taux d'identification

Pour déterminer le taux d'identifications correctes, les images de tests utilisées doivent appartenir aux personnes présentes dans l'ensemble d'apprentissage, autrement dit, on ne va pas utiliser pour le test des images de personnes inconnues.

Le taux d'identification nous indique le nombre de fois où le système a bien reconnu la personne de test. Pour le mesurer on utilise la totalité de la base de données, il est alors égal à la moyenne des taux d'identifications correctes obtenus lors de chaque calcul, c'est-à-dire lors de chaque test.

Le taux d'identification obtenu est de **43%**.

4. CONCLUSION

En résumé, l'algorithme LDA permet d'effectuer une véritable séparation de classes, selon un critère mathématique qui minimise les variations entre les images d'un même individu (variations intra-classe) tout en maximisant les variations entre les images d'individus différents (variations interclasses). Cette méthode est très simple à implémenter, le temps d'exécution de ces fonctions principales est relativement petit. Cependant, elle n'est pas précise pour la reconnaissance FKP en termes de taux d'erreur.

Afin de contourner ce problème, on peut utiliser la LDA avec une autre méthode de reconnaissance globale comme la PCA (une sorte de multimodalité), ou encore faire une fusion de plusieurs techniques pour améliorer les performances de reconnaissance [3].

Bibliographies

- [1] W. Zhao, R. Chellappa, P. J. Phillips and A. Rosenfeld, Face Recognition : A Literature Survey, ACM Computing Surveys, Vol.35, No.4, December 2003 : Principal-Component Analysis.
- [2] Nicolas MORIZET. Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris. Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications, 2009.
- [3] Zahra S. Shariatmadar, Karim Faez. A Novel Approach for Finger-Knuckle-Print Recognition Based on Gabor Feature Fusion. 4th International Congress on Image and Signal Processing, IEEE, 2011.