

COMPARAISON DES METHODES DE REDUCTION D'ESPACE ET L'APPLICATION DES SVMS POUR LA CLASSIFICATION DANS L'AUTHENTIFICATION DE VISAGES

M.BELAHCENE, A. OUAMANE, M. BOUMEHREZ, A. BENAKCHA

Université Mohamed Khider Biskra,
belahcene_mebnaf@yahoo.fr

RÉSUMÉ

Dans cet article, nous présenterons quatre méthodes d'extraction de caractéristiques à base de réduction d'espace à une dimension: L'Analyse en Composantes Principales (ACP), L'Analyse Discriminante Linéaire(ADL), le Modèle Discriminant Linéaire Amélioré de Fisher (EFM) et la ADL Directe (ADLD) et deux méthodes à deux dimensions : l'Analyse Discriminante Linéaire Bidimensionnelle Orientée en Lignes (ADL2DOL) et en Colonnes (ADL2DOC). Une présentation théorique de ces approches et leurs applications au domaine du visage sur la base de données XM2VTS est faite. Puis une étude comparative entre ces algorithmes est effectuée. La meilleure méthode de réduction d'espace est retenue. Pour la classification nous proposons d'utiliser un nombre de machines à vecteurs de support (SVM) égal ou nombre des clients.

Mots clés - extraction de caractéristiques; réduction d'espace ; machines à vecteurs de support.

1 INTRODUCTION

L'identification et la vérification des visages ont attirés l'attention des chercheurs depuis quelques décennies, et restent encore et toujours un sujet de recherche attractif et très ouvert. Beaucoup de connaissances dans les domaines de la reconnaissance des formes, du traitement d'images, des statistiques ont été appliquées au domaine de la reconnaissance du visage. En plus, les capacités grandissantes des moyens informatiques et l'existence de bases de données de grandes tailles ont permis de mettre au point des algorithmes et des approches de plus en plus complexes et par conséquent, les performances de reconnaissance se sont trouvées améliorées. La reconnaissance faciale possède plusieurs avantages sur les autres technologies biométriques : elle est naturelle, non intrusive et facile à utiliser. Parmi les six attributs biométriques considérés par Hietmeyer [1], les caractéristiques faciales marquent un score de compatibilité le plus élevé dans un système MRTD ("Machine Readable Travel Documents"), ce score étant basé sur plusieurs facteurs d'évaluation tels que l'enrôlement, le renouvellement des données, les requis matériels et la perception des utilisateurs. Les méthodes de reconnaissance faciales peuvent être séparées en deux grandes familles :

i) les méthodes globales (ou holistiques) [5], [16], [24] basées sur des techniques d'analyse statistique bien connues. Les méthodes globales de classification par réduction d'espace restent parmi les techniques les plus utilisées et les plus populaires dans le domaine de la reconnaissance du visage 2D.

Les méthodes locales basées sur des modèles utilisant des connaissances à priori que l'on possède sur la morphologie du visage et s'appuient en général sur des points caractéristiques de celui-ci. Kanade [2] présenta un des premiers algorithmes de ce type.

Le choix a été fait de se concentrer sur les méthodes globales de classification par réduction d'espace car elles restent parmi les techniques les plus utilisées et les plus populaires dans le domaine de la reconnaissance du visage 2D. En plus, elles sont basées sur des techniques d'analyse statistique bien connues. Il n'est pas nécessaire dans ce cas de repérer certains points caractéristiques du visage (comme les centres des yeux, les narines, le centre de la bouche, etc...). Dans ces méthodes, les images de visage sont traitées de manière globale et sont généralement transformées en vecteurs, plus faciles à manipuler pour les méthodes : ACP, ADL, EFM et ADLD. Mais reste sous forme de matrices pour ADL2DOL et ADL2DOC. L'objectif de ces méthodes est de trouver une base réduite de projection qui optimise un certain critère et l'espace original est ensuite projeté sur cette base de dimension inférieure. De ce fait on réduit considérablement la complexité des calculs tout en conservant l'information discriminante entre les images. La classification est habituellement effectuée selon une mesure de distance simple dans l'espace multidimensionnel final. 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. Ensuite nous proposons l'utilisation pour la classification un classifieur à deux classes client ou imposteur par machines à vecteurs

de support SVM pour chaque client. Finalement, le modèle ainsi étudié est appliqué sur les images de visages de la base de données XM2VTS selon son protocole associé (Protocole de Lausanne 1).

2 LES MÉTHODES DE RÉDUCTION D'ESPACE

Une image du visage est un signal à 2 dimensions, acquis par un capteur digital. Ce capteur codera la couleur ou l'intensité des différents points de l'image dans une matrice de pixels à deux dimensions dans l'espace des images, nous devons spécifier une valeur pour chaque pixel de cette image. Le nombre de points constituant cet espace devient rapidement très grand, même pour les images de petite dimension. Cette dimensionnalité pose un certain nombre de problèmes pour les algorithmes de reconnaissance, qui se basent sur cette représentation de l'image, à savoir :

Dans un contexte de la reconnaissance de visages, travailler dans un grand espace pose un problème de complexité de calcul.

Pour les méthodes paramétriques, le nombre de paramètres à estimer peut rapidement dépasser le nombre d'échantillons d'apprentissage, ce qui pénalise l'estimation.

Pour les méthodes non paramétriques, le nombre d'exemples nécessaires afin de représenter efficacement la distribution des données peut être insuffisant.

En 1994, Ruderman a démontré que les images naturelles possèdent une grande redondance statistique [3]. En 1996, Penev [4] a démontré que dans le cas précis des images normalisées des visages, cette redondance statistique est d'autant plus forte.

L'avantage de la redondance statistique est qu'elle permet une extraction d'une structure simple des caractéristiques importantes et pertinentes de l'image du visage. Cette structure permettrait de représenter le visage tout en gardant l'information la plus importante, et par conséquent, de réduire la dimensionnalité de l'espace visage. Tout l'intérêt des approches globales est la construction de cette base de projection qui permettra de comparer, de reconnaître ou d'analyser l'information essentielle des visages.[5]

2.1 Analyse en Composantes Principales ou ACP

Le premier système de reconnaissance de visages qui a permis d'obtenir des résultats significatifs a été réalisé par Turk et Pentland [6] en utilisant la méthode dite des « Eigenfaces ». La base orthogonale Φ définit un espace appelé « FaceSpace » de dimension m inférieure à la taille des vecteurs images ($m \ll n$) en résolvant l'équation (1)

$$C\Phi = \Phi \quad (1)$$

$$C = \sum (x - \bar{x})(x - \bar{x})^T \quad (2)$$

où C est la matrice de covariance du vecteur image x . $\Phi = [\Phi_1, \dots, \Phi_m]^T$ est la matrice des vecteurs propres composée des vecteurs propres correspondant aux m plus grandes valeurs propres, et Λ est la matrice des valeurs propres associées [7].

L'ACP ne tient pas compte de l'aspect (discrimination) des classes. Alors une solution est proposée pour résoudre ce nouveau problème est d'employer l'Analyse Discriminante Linéaire (ADL) dans le but même de réaliser une séparabilité élevée entre les différentes classes.

2.2 Analyse Discriminante Linéaire (ADL)

L'ACP est d'abord utilisée pour projeter les images dans un espace de données inférieur. Le but de l'ADL est de maximiser les distances inter-classes tout en minimisant les distances intra-classes, ce qui revient à retrouver la matrice de transformation W qui maximise le critère [5] :

$$J(W) = \frac{W^T S_b W}{W^T S_w W} \quad (3)$$

Donc W est optimale pour

$$W_{opt} = \underset{W}{\operatorname{argmax}} \left(\frac{|W^T S_b W|}{|W^T S_w W|} \right) = [W_1, W_2, \dots, W_m] \quad (4)$$

Soit l'ensemble d'apprentissage contenant L classes et chaque classe X_i contient n_i échantillons. Les matrices intra-classe (S_w) et inter-classe (S_b) sont définis comme :

$$S_w = \sum_{i=1}^L \sum_{x_k \in X_i} (x_k - \bar{m}_i)(x_k - \bar{m}_i)^T \quad (5)$$

$$S_b = \sum_{i=1}^L n_i (\bar{m}_i - \bar{m})(\bar{m}_i - \bar{m})^T \quad (6)$$

\bar{m} est le moyenne de toute les images d'apprentissage, \bar{m}_i est les moyennes des images dans chaque classe X_i , et \bar{x}_k est l'échantillon appartenant à la classe X_i , La solution de problème dans l'équation (4) est le calcul les vecteurs propres et les valeurs propres,

$$S_b W = \lambda S_w W \quad (7)$$

W contient les vecteurs propres par leurs valeurs propres associés dans l'ordre décroissant. L'ADL exige un grand nombre d'échantillons de l'ensemble et crée un problème de sur-ajustement aux données d'apprentissage et généralise ainsi mal aux nouvelles données de test. Alors la solution est le Modèle Discriminant Linéaire Amélioré de Fisher (Enhanced Fisher Model) [8].

2.3 Le Modèle Discriminant Linéaire Amélioré de Fisher (Enhanced Fisher Linear Discriminant Model (EFM))

L'ACP est d'abord utilisée pour projeter les images dans un espace de données inférieur. Le modèle Discriminant Linéaire Amélioré de Fisher améliore la capacité de généralisation de l'ADL en décomposant la procédure ADL en diagonalisation simultanée des deux matrices de dispersion S_w et S_b [8]. Blanchissons d'abord S_w :

$$\Theta^{-\frac{1}{2}} \Phi^T S_w \Theta^{-\frac{1}{2}} = I \tag{8}$$

Où, $\Theta \in R^{m \times m}$ et Φ sont la matrice des vecteurs propres et la

matrice diagonale des valeurs propres de S_w respectivement. En second lieu l'EFM procède à calculer la matrice de dispersion inter-classe K_b comme suit :

$$K_b = \Theta^{-\frac{1}{2}} \Phi^T S_b \Phi \Theta^{-\frac{1}{2}} \tag{9}$$

Diagonalisons maintenant la nouvelle matrice de dispersion inter-classe K_b :

$$K_b \Psi = \Psi \Lambda \tag{10}$$

Où $\Psi, \Lambda \in R^{m \times m}$ sont la matrice des vecteurs propres et la matrice diagonale des valeurs propres de K_b respectivement. La matrice de transformation globale de l'EFM est définie comme suit [10] :

$$W = \Phi \Theta^{-1/2} \Psi \tag{11}$$

2.4 La ADL Directe (ADLD)

Une nouvelle approche, appelée **ADLD**, a été proposée dans [10] afin de maximiser le critère de **Fisher**. La première étape de cette approche est la diagonalisation de la matrice S_b par le calcul de la matrice V :

$$V^T S_b V = \Lambda \tag{12}$$

Avec : $V^T V = I$.

Le problème est alors ramené à la résolution d'un problème de valeurs propres. Comme la matrice S_b peut être singulière, Λ peut contenir des valeurs propres nulles ou très faibles. Ces valeurs ainsi que les vecteurs propres associés doivent être écartés car une projection dans la direction de ces vecteurs n'apporte aucune information discriminante entre les classes. Soit Y la sous-matrice composée des m premières colonnes de V

$$Y^T S_b Y = D_b > 0 \tag{13}$$

Avec D_b la sous-matrice de Λ . En multipliant par $(D_b^{-1/2})^T$ et

$D_b^{-1/2}$ de part et d'autre on aboutit à :

$$(Y D_b^{-1/2})^T S_b (Y D_b^{-1/2}) = D_b$$

En posant $Z = Y D_b^{-1/2}$;
Nous obtenons :

$$Z^T S_b Z = D_b \tag{14}$$

On constate que Z permet de réduire la dimension de S_b . Considérons la diagonalisation de la matrice $Z^T S_w Z$ par la résolution du problème des valeurs propres :

$$U^T Z^T S_w Z U = D_w \tag{15}$$

Avec : $U^T U = I$.

D_w peut contenir des valeurs nulles sur la diagonale. L'objectif est de minimiser l'éparpillement des inter-classes. Il est donc important de garder les vecteurs de projection associés aux valeurs propres les plus faibles, spécialement les valeurs nulles, et d'écartier ceux associés aux valeurs propres les plus fortes. En posant la matrice $A = U^T Z^T$, A permet la diagonalisation du numérateur et du dénominateur du critère de **Fisher** :

$$A S_w A^T = D_w \quad ; \quad A S_b A^T = I \tag{16}$$

En posant $\phi = D_w^{-1/2} A$, nous obtenons la matrice de

projection qui répond au critère de Fisher [5].

2.5 L'Analyse Discriminante Linéaire Bidimensionnelle Orientée (ADL2DO)

L'ADL2DO se décline en deux versions :

- l'ADL2D Orientée en Lignes (ADL2DOL), qui est proposée dans [11],
- l'ADL2D Orientée en Colonnes (ADL2DOC).

Présentons dans un premier temps l'ADL2DOL.

Considérons une matrice de projection P , de taille $w \times k$, et la projection suivante :

$$X_i^P = X_i P \quad (17)$$

Où X_i^P est la matrice de taille $h \times k$ correspondant à la projection de la matrice-image X_i sur P , et constitue la matrice de la signature associée à l'image X_i par l'ADL2DOL. Nous recherchons la matrice P qui maximise après projection la distance Euclidienne entre classes différentes tout en minimisant la distance entre les éléments provenant d'une même classe. Sous l'hypothèse que les lignes de pixels des images constituent des vecteurs gaussiens et que les lignes provenant de classes différentes ont la même covariance intra classes, on peut montrer que la matrice P^* maximisant le critère de Fisher généralisé suivant :

$$P^* = \underset{P \in \mathbb{R}^{w \times k}}{\operatorname{Argmax}} \frac{|P^T S_b P|}{|P^T S_w P|} \quad (18)$$

Où S_w et S_b sont respectivement les matrices de covariance intra et inter classes généralisées de Ω :

$$S_w = \sum_{c=1}^C \sum_{X_i \in \Omega_c} (X_i - \bar{X}_c)^T (X_i - \bar{X}_c) \quad (19)$$

$$S_b = \sum_{c=1}^C n_c (\bar{X}_c - \bar{X})^T (\bar{X}_c - \bar{X}) \quad (20)$$

Où \bar{X}_c est la matrice moyenne des n_c visages appartenant à la classe Ω_c et \bar{X} est la matrice moyenne de tous les visages de Ω . Sous l'hypothèse que S_w est inversible, les k colonnes de la matrice P^* sont les k premiers vecteurs propres de la matrice $S_w^{-1} S_b$ (c.-à-d. ceux associés aux plus grandes valeurs propres).

De la même manière, pour l'ADL2DOC, la projection considérée est la suivante :

$$X_i^Q = Q^T X_i \quad (21)$$

Où Q est une matrice de projection de taille $h \times k$, Q^T est sa transposée et la matrice X_i^Q de taille $k \times w$, constitue la signature associée au visage X_i par l'ADL2DOC. Sous les hypothèses de multinormalité et d'homoscédasticité des colonnes des matrices-images, nous pouvons considérer que la matrice Q^* , optimale pour une taille $h \times k$ fixée, maximise le critère de Fisher généralisé suivant :

$$Q^* = \underset{Q \in \mathbb{R}^{h \times k}}{\operatorname{Argmax}} \frac{|Q^T S_b Q|}{|Q^T S_w Q|} \quad (22)$$

où S_w et S_b désignent respectivement les matrices de covariance intra et inter classes généralisées de la base constituée des $(X_i^T)_{i \in \{1, \dots, n\}}$

$$\Sigma_w = \sum_{c=1}^C \sum_{X_i \in \Omega_c} (X_i - \bar{X}_c) (X_i - \bar{X}_c)^T \quad (23)$$

$$\Sigma_b = \sum_{c=1}^C n_c (\bar{X}_c - \bar{X}) (\bar{X}_c - \bar{X})^T \quad (24)$$

On peut montrer que les k colonnes de la matrice Q^* sont les vecteurs propres de $\Sigma_w^{-1} \Sigma_b$ associés aux plus grandes valeurs propres [12].

3 LES MACHINES A VECTEURS DE SUPPORT (SVM)

Le but du SVM est de trouver une séparatrice qui minimise l'erreur de classification sur l'ensemble d'apprentissage mais 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 figure 1. Ces éléments sont appelés vecteurs de support car c'est uniquement sur ces éléments de l'ensemble d'apprentissage qu'est optimisée la séparatrice.

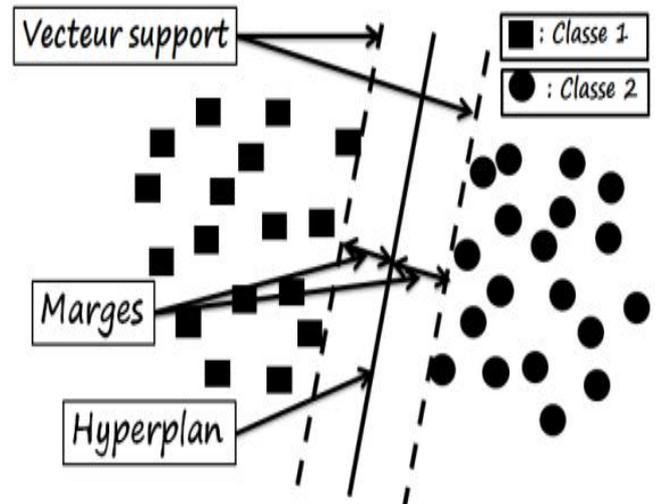


Figure 1: Séparation linéaire dans un espace à deux dimensions.

Tout classifieur a pour but de classier un élément x , dans l'une des classes possibles. Dans notre problème il y a deux classes, Client ou Imposteur, dont l'étiquette sera noté y avec $y = -1$ et 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 :

$$y = f(x) \quad (25)$$

Le SVM a pour but de trouver la meilleure séparatrice linéaire (en terme de marge maximale) 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 :

$$w \cdot k(x) + b = 0 \quad (26)$$

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

$$h(x_i) = \frac{w \cdot K(x_i) + b}{\|w\|} \quad (27)$$

Pour maximiser la marge, il faut donc minimiser $\|w\|$ tout en maximisant $w.k(x_i) + b$ 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 $w.k(x_i) + b = \pm 1$. La résolution de ce problème d'optimisation est faite par l'utilisation des multiplicateurs de **Lagrange** où le **Lagrangien** est donné par :

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i (y_i (w.k(x_i) + b) - 1) \quad (28)$$

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 [14].

4 EVALUATION EXPÉRIMENTALE

4.1 Base de données

Nos expériences sont exécutées sur des images frontales de visage de la base de données XM2VTS. C'est une base multimodale développée au sein du projet européen ACTS, elle est utilisée pour la vérification d'identité, elle contient 8 images par visage de 295 personnes. La base de données XM2VTS a été réalisée sur une longue période ce qui a permis d'obtenir plusieurs images d'une même personne et donc une grande variabilité d'apparence (changement de coiffure, présence et/ou absence de lunettes, etc...). Par contre, seules les expressions neutres ont été considérées. Pour la tâche de vérification, un protocole standard d'estimation de performances a été développé. Appelé «Lausanne protocol splits randomly», il existe deux configurations différentes, la configuration I et la configuration II. Nous n'utiliserons que la configuration I puisqu'elle est la plus dure. Elle consiste à séparer les individus en deux classes, Client et Imposteur. Le groupe Client contient 200 sujets, alors que le groupe Imposteur est divisé en 25 imposteurs pour l'évaluation et 70 imposteurs pour le test. Huit images des quatre sessions sont utilisées. La répartition des photos dans les différents ensembles est présentée dans le tableau 1 [15].

Tableau 1 Répartition des photos dans les différents ensembles.

Ensemble	Clients	Imposteurs
Apprentissage	600 images (3 par personne)	0 images
Evaluation	600 images (3 par personne)	200 images (8 par personne)
Test	200 images (2 par personne)	560 images (8 par personne)



Figure 2: Exemples des images de la base de données XM2VTS (a) des personnes différentes, (b) la même personne

4.2 Mesure de la performance d'un système d'authentification de visage

Tout d'abord, afin de comprendre comment déterminer la performance d'un système biométrique, il nous faut définir clairement quatre critères principaux [16] : Le premier critère s'appelle le taux de faux rejet ou TFR, ce taux représente le pourcentage de personnes censées être reconnues mais qui sont rejetées par le système. Le deuxième critère est le taux de fausse acceptation ou TFA, ce taux représente le pourcentage de personnes censées ne pas être reconnues mais qui sont tout de même acceptées par le système. Le troisième critère est connu sous le nom de taux d'égale erreur ou TEE, ce taux correspond à l'endroit où TFR=TFA. Le quatrième critère est le taux de réussite (TR = 100-(TFR+TFA)).

La figure 3.a illustre le TFR et le TFA à partir de distributions des scores Clients et Imposteurs tandis que le TEE est représenté sur la figure 3.b.

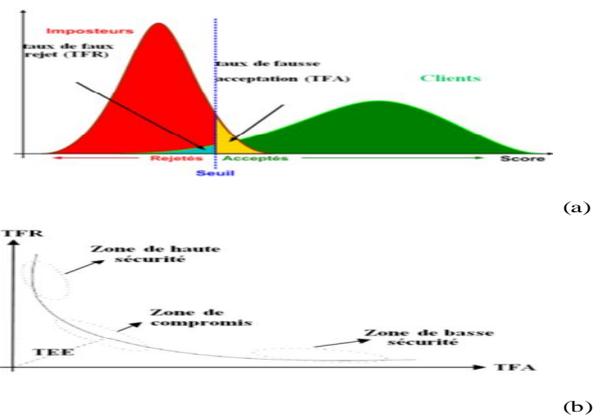


Figure 3: (a) Illustration du TFR et du TFA. (b) Courbe caractéristique de fonctionnement (ROC) d'un système de Vérification Biométrique.

4.2.1 Intervalle de confiance

Nous devons faire face à une autre difficulté de l'évaluation d'un système biométrique. En général, on ne dispose que de peu de données de chaque personne et de peu de personnes. Il est alors impératif de mesurer en plus des taux d'erreurs calculés, une mesure de confiance associée. Deux types de mesure des intervalles de confiance sont introduits par Mellakh [5], Allano [14] :

Une basée sur une méthode non-paramétrique appelée "bootstrap" et une basée sur une méthode paramétrique.

Dans notre article nous utilisons la méthode paramétrique pour sa simplicité de calcul. Dans ce qui suit nous essayons de donner le principe de cette méthode. L'hypothèse principale faite lorsqu'on utilise cette méthode d'estimation de l'intervalle de confiance est que les scores ou les distances sont issus de variables indépendantes et identiquement distribuées même pour les scores d'une personne, c'est-à-dire que tous les scores sont issus de la même loi et sont mutuellement indépendants. Cette hypothèse semble très stricte mais est nécessaire pour l'application des théorèmes. Ceci dit, elle n'est généralement pas vérifiée en pratique. Il s'agit ensuite d'estimer les taux d'erreur TFA(θ) et TFR(θ) pour une ou plusieurs valeurs du seuil θ . Pour estimer ces erreurs, l'estimation des fonctions de répartition, appelées "fonctions de répartition empiriques", pour les deux classes "Client" et "Imposteur" doit être réalisée par une loi normale. L'estimation des intervalles de confiance des taux d'erreur TFA et TFR à un seuil θ est obtenue par :

$$\text{TFA}(\theta) \in \left[\widehat{\text{TFA}}(\theta) - \lambda \times \sqrt{\frac{\widehat{\text{TFA}}(\theta)(1-\widehat{\text{TFA}}(\theta))}{N_i}}, \widehat{\text{TFA}}(\theta) + \lambda \times \sqrt{\frac{\widehat{\text{TFA}}(\theta)(1-\widehat{\text{TFA}}(\theta))}{N_i}} \right] \quad (29)$$

$$\text{TFR}(\theta) \in \left[\widehat{\text{TFR}}(\theta) - \lambda \times \sqrt{\frac{\widehat{\text{TFR}}(\theta)(1-\widehat{\text{TFR}}(\theta))}{N_c}}, \widehat{\text{TFR}}(\theta) + \lambda \times \sqrt{\frac{\widehat{\text{TFR}}(\theta)(1-\widehat{\text{TFR}}(\theta))}{N_c}} \right] \quad (30)$$

Avec $\widehat{\text{TFA}}(\theta)$, $\widehat{\text{TFR}}(\theta)$ les valeurs calculées pour un test donné. N_c les scores "Client" et N_i les scores "Imposteur" du test. Pour des intervalles de confiance à 90%, on a $\lambda = 1.645$ et pour des intervalles de confiance de 95%, on a $\lambda = 1.96$.

4.3 Résultats

Chaque image est constituée de plusieurs informations comme : la couleur, l'arrière plan, les cheveux, les cols de chemise, les oreilles etc... Pour cela, la première étape nécessaire est de découper l'image par une fenêtre rectangulaire de taille 161x121 centrée autour des caractéristiques les plus stables liées aux yeux, aux sourcils, au nez et à la bouche. Une décimation de facteur 2 pour réduire par 4 la taille de l'image découpée puis nous avons utilisée l'espace de couleur HSV (Hue, Saturation, Value) parce que ce sont les plus utilisées dans la littérature [5].

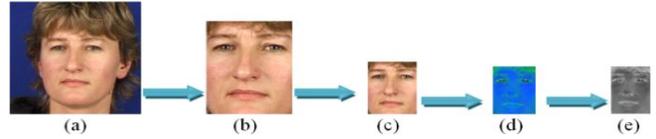


Figure 4: (a) Image originale, (b) Image découpée, (c) Image décimée, (d) Image en système HSV, (e) La composante S de HSV.

Nous considérons la composante S " Saturation " comme caractéristique selon [17] puis nous faisons la comparaison des performances des méthodes de réduction d'espace (sections 2.1, 2.2, 2.3 et 2.4). Nous utilisons la distance corrélation normalisée [18] (équation 31) pour la mesure similarité.

$$S(A, B) = \frac{A^T B}{\|A\| \|B\|} \quad (31)$$

Cette fonction calcule simplement le cosinus de l'angle entre les deux vecteurs caractéristiques A et B. Une valeur élevée de corrélation normalisée correspond à une bonne similarité entre les deux vecteurs.

Les taux d'égale erreur TEE obtenus sur l'ensemble d'évaluation des quatre méthodes (ACP, ADL, EFM et ADLD) pour l'authentification des visages en appliquant corrélation normalisée pour la mesure similarité sont représentés sur la figure 5. Nous pouvons constater que la méthode EFM est mieux performante que l'ADL suivie de l'ADLD suivie de l'ACP en employant un nombre restreint de caractéristiques (vecteurs propres) dans notre base de données XM2VTS.

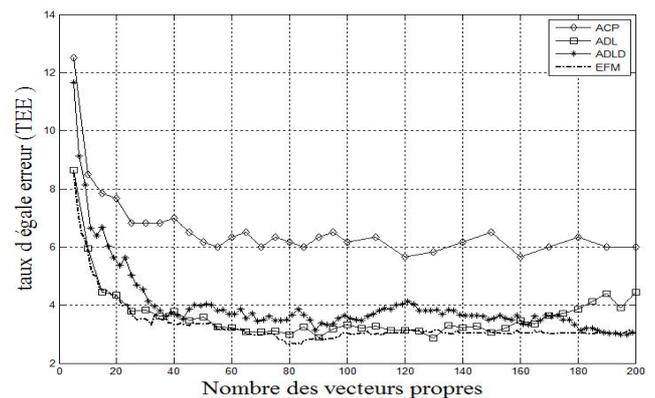


Figure 5: Comparaison des performances des méthodes ACP, ADL, EFM et ADLD dans l'ensemble d'évaluation.

Le tableau 2 montre les résultats obtenus dans l'ensemble d'évaluation et l'ensemble de test. Nous constatons que le résultat obtenu avec ACP+EFM est le meilleur avec un TEE=2.66±0.13% et un TR=94.33±1.49% en utilisant seulement un nombre de caractéristiques égale 80.

Tableau 2: Comparaison des performances des méthodes ACP, ADL, EFM et ADLD dans l'ensemble d'évaluation et de test (intervalle de confiance paramétrique à 95%).

Méthode	Ensemble évaluation		Ensemble de test		Np
	TEE%	TFR%	TFA%	TR%	
ACP	5.7 ±1.04	2.7 ±1.58	8.1 ±0.17	89.2 ±1.75	200
ACP + ADL	2.83 ±0.74	2 ±0.08	4.12 ±1.94	93.88±2.03	90
ACP + EFM	2.66 ±0.13	2 ± 1.37	3.66 ±0.12	94.33±1.49	80
ACP +ADLD	3 ±0.72	2.1 ± 1.4	4.3 ±0.12	93.6 ±1.53	195

Nous utilisons ensuite les deux méthodes d'extraction des caractéristiques l'Analyse Discriminante Linéaire Bidimensionnelle Orientée en Lignes (ADL2DOL) et en Colonnes (ADL2DOC). Pour ce type d'analyse nous utilisons la distance proposé dans [12] « l'Assembled Matrix Distance: AMD » (équation 33) pour la mesure similarité.

$$d(Y_i, Y_j) = \left(\sum_{k=1}^{d_1} \left(\sum_{k=1}^n (y_{ik}^{(i)} - y_{jk}^{(j)})^2 \right)^{\frac{1}{2}} \right)^{\frac{1}{p}} \text{ avec } p > 0 \quad (32)$$

Avec : $y_k^{(i)} = [y_{1k}^{(i)} y_{2k}^{(i)} \dots y_{d_1k}^{(i)}]$ et $y_k^{(j)} = [y_{1k}^{(j)} y_{2k}^{(j)} \dots y_{d_1k}^{(j)}]$ les deux matrices caractéristiques.

Les figures 6 et 7 illustrent les taux d'égal erreur TEE obtenus sur l'ensemble d'évaluation pour les méthodes (ADL2DOL, ADL2DOC) en appliquant la AMD pour la mesure similarité avec $p=0.125, 0.5, 1, 2$.

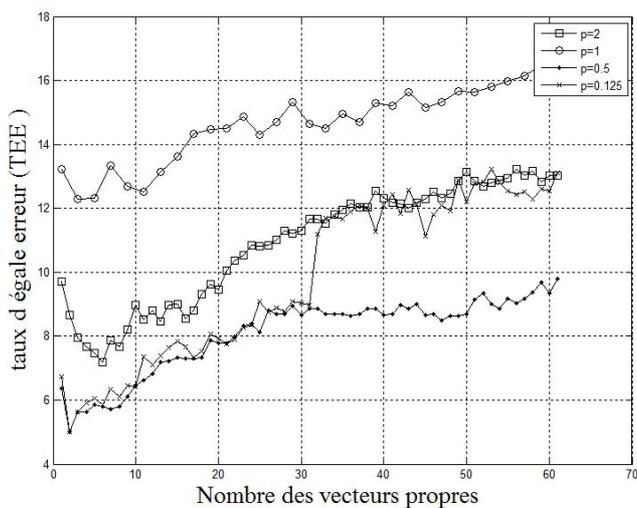


Figure 6: Taux d'égal erreur dans l'ensemble d'évaluation par différentes fonctions de mesure de distance pour la méthode LDA2DOL.

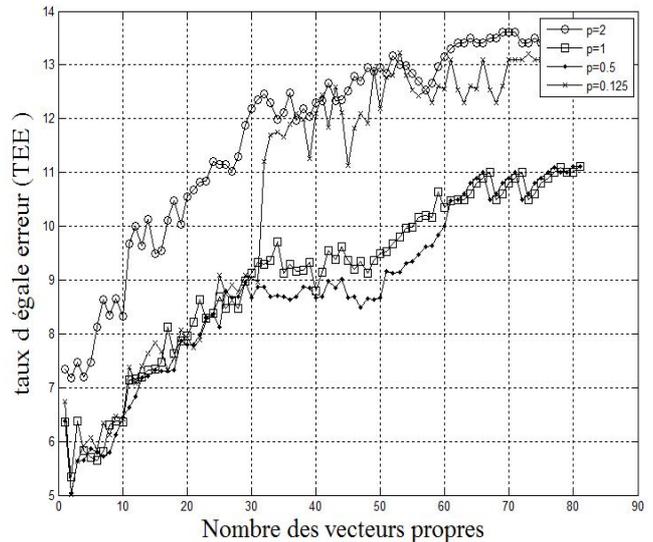


Figure 7: Taux d'égal erreur dans l'ensemble d'évaluation par différentes fonctions de mesure de distance pour la méthode LDA2DOC.

Nous remarquons que le meilleur résultat est obtenu par $p=0.125$ pour les deux méthodes d'extraction des caractéristiques par un nombre restreint des vecteurs propres. Le tableau 3 montre les résultats obtenus dans l'ensemble d'évaluation et l'ensemble de test pour la meilleure distance ($p=0.125$ et Np : Nombre de paramètres caractéristiques).

Tableau 3: Comparaison des performances des méthodes LDA2DOL et LDA2DOC dans l'ensemble d'évaluation et test.

Méthodes	Ensemble évaluation		Ensemble de test		Np
	TEE%	TFR%	TFA%	TR%	
LDA2DOL	5.1 ±0.98	2±1.37	6.3±0.15	91.7±1.52	2*81
LDA2DOC	5.01±0.97	2±1.37	6.19±0.15	91.81±1.5	2*61

Le tableau 3 montre que les deux méthodes LDA2DOL et LDA2DOC donnent presque le même résultat avec un nombre de caractéristiques $2*81=162$ pour LDA2DOL et $2*61=122$ pour LDA2DOC. Nous remarquons que ces méthodes à deux dimensions n'améliorent pas la performance d'authentification de visage par rapport aux ADL, EFM et ADLD car la base de données XM2VTS a été réalisée sur une longue période ce qui a permis d'obtenir plusieurs images d'une même personne et donc une grande variabilité d'apparence (changement de coiffure, présence et/ou absence de lunettes, etc...). Par contre, seules les expressions neutres ont été considérées, donc nous proposons d'utiliser ces méthodes pour les bases de données qui contiennent plusieurs expressions.

4.4 La méthode proposée

Dans cet article nous retenons que la méthode ACP+EFM est la meilleure méthode de réduction d'espace. Nous l'utiliserons donc dans tout ce qui suit.

La méthode à vaste marge SVM est utilisée comme méthode de classification à deux classes. Pour cela, nous proposons d'utiliser un nombre de SVMs égale au nombre des Clients (200 Clients dans le cas de la XM2VTS). La figure 8 montre l'apprentissage des SVMs. On voit bien que les deux entrées du premier SVM1 sont composées :

Par les trois vecteurs caractéristiques réduits associés aux trois poses du Client1, et des deux cents vecteurs caractéristiques réduits des huit poses des vingt cinq Imposteurs.

Pour les deux cent SVMs, il n'y a qu'une seule entrée qui varie c'est celle correspondant aux clients : SVM₁ est associée au Client1, SVM₂ au Client2,..... SVM₂₀₀ au Client200. Les 200 vecteurs caractéristiques réduits des 8 poses des 25 imposteurs sont maintenus pour les 200 SVMs. Les vecteurs étiquettes sont les mêmes pour chaque SVM avec, -1 correspondant à la classe des Imposteurs et +1 à la classe des Clients.

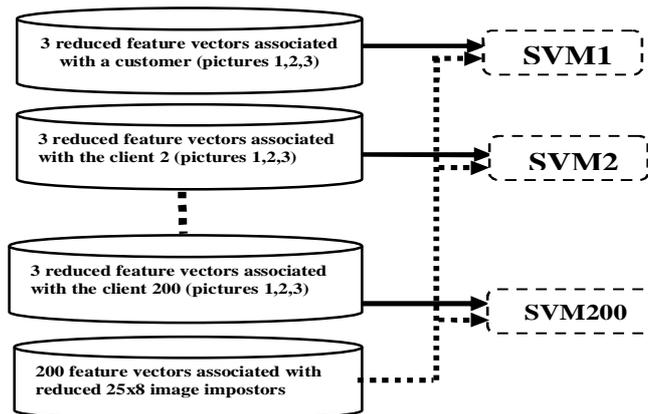


Figure 8: Apprentissage des SVM

Nous choisissons d'utiliser une machine à vecteurs de support (SVM) avec un noyau RBF (Radial Basis Function ou fonction à base radiale) (voir équation 25).

Le SVM a été implémenté en utilisant la librairie LibSVM disponible gratuitement (<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>). Le noyau RBF utilisé est de la forme :

$$K_{RBF}(u, v) = e^{-\gamma \|u-v\|^2} \quad (33)$$

Où γ est un paramètre qui règle la largeur de la marge. Le SVM nécessite également le réglage du paramètre C qui règle le compromis entre la largeur de la marge et le nombre d'erreurs admissibles.

Les figures 9 et 10 présentent les taux d'égale erreur (TEE) dans l'ensemble d'évaluation et taux de réussite (TR) dans l'ensemble de test en fonction du nombre des caractéristiques de la méthode de réduction d'espace

ACP+EFM. La méthode de classification est celle qui utilise un nombre des SVMs égale au nombre des Clients.

Nous avons remarqué dans la figure 9 que le TEE est égale 0% depuis un nombre de caractéristiques égale à 40 c'est un TEE parfait et cela dans l'ensemble d'évaluation. Mais d'après la figure 10 nous remarquons que dans l'ensemble de test le TR prend une valeur intéressante et stable depuis un nombre de caractéristiques égale 90.

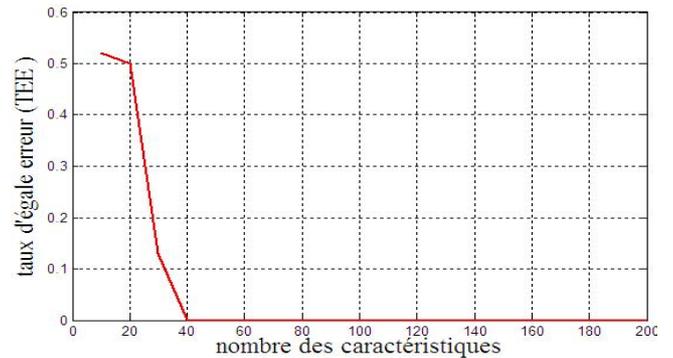


Figure 9: Taux d'égale erreur (TEE) dans l'ensemble d'évaluation en fonction des caractéristiques.

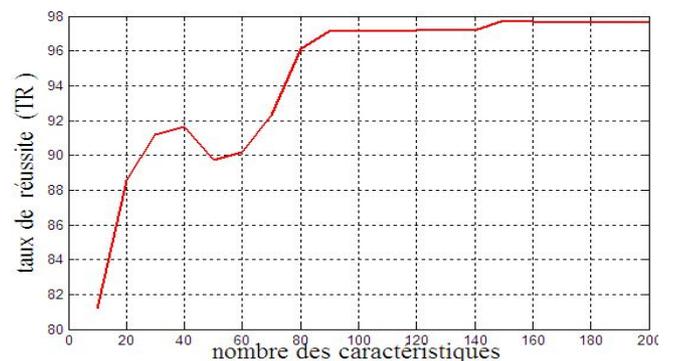


Figure 10: Taux de réussite (TR) dans l'ensemble de test en fonction des caractéristiques.

Nous présentons dans le tableau 4 les résultats dans l'ensemble d'évaluation et l'ensemble de test, le nombre des caractéristiques et le temps de calcul pour la méthode proposée. Notre travail est exécuté avec un ordinateur : Intel Pentium Dual CPU 2.2 GHz, 1.49 Go de RAM et le langage de programmation utilisé est le MATLAB R2009b.

Tableau 4: Performance de notre système d'authentification de visages.

Ensemble d'évaluation	Ensemble de test			Np	Tps de calcul
	TEE %	TFA%	TFR %		
0±0	1.5±0.09	0.78±0.01	97.72±1.46	150	0.32 S

Nous pouvons affirmer à ce stade que nous obtenons un parfait taux d'égale erreur avec $TEE=0\pm 0\%$ dans l'ensemble d'évaluation et un bon taux de réussite $TR=97.72\pm 1.46$ dans l'ensemble de test avec un temps de calcul T_c satisfaisant $t=0.32$ S. Notre méthode est plus performante que la méthode qui utilise la classification basée sur la distance de corrélation normalisée avec un :

$TEE=2.66 \pm 0.13\%$ et $TR=94.33 \pm 1.49$.

En conclusion de cette série de résultats, un tableau de synthèse (tableau 5) permet de comparer la performance de notre systèmes d'authentification de visages par rapport à la performance obtenue dans d'autres travaux sur la base de données XM2VTS selon le protocole de Lausanne I.

Nous pouvons remarquer que la performance de notre système d'authentification de visages et presque équivalente à celle obtenue en 2009 par Salimi dans l'ensemble de test. En plus notre système est parfait dans l'ensemble d'évaluation. Notre objectif était l'amélioration du système de reconnaissance de visages nous affirmons en nous basant sur les résultats obtenus que notre objectif est bien atteint.

Tableau 5 : Tableau de synthèse de performances, obtenues dans l'authentification de visages.

Date	Auteur	Méthodes	Évaluation(%)	Test (%)
2006	Saigaa et al[19]	couleur +EFM	ACP TEE=1.51	TFA=1.49, TFR=1.5, TR=97.01
2007	Yan et al[20]	Weighted Variant Effectiveness	for TEE=2.37	/
2007	Kotsia et al[21]	Discriminant non-negative matrix factorization algorithms	TEE=0.7	/
2009	Ejarque et al[22]	Fisherfaces +SVM	TEE=1.25	/
2009	Salimi et al[23]	KPCA+LDA	TFA=1.08, TFR=1.17	TFA=1.23, TFR=1, TR=97.77
2011	Notre système	PCA+EFM+200 SVMs	TEE=0	TFA=1.5, TFR=0.78, TR=97.72

5 CONCLUSION

Dans le présent article nous avons réalisé une étude comparatives de six méthodes de réduction d'espace et nous concluons que les méthodes d'extraction des caractéristiques : ADL, EFM et ADLD sont performants que l'ADL2DO et la meilleure méthode de réduction d'espace reste l'ACP+EFM. Ensuite nous avons proposé d'utiliser un nombre de SVMs égale au nombre des Clients et nous pouvons dire que l'efficacité de notre système est

justifiée par un TEE parfait dans l'ensemble d'évaluation, un bon taux de réussite avec $TR=97.72\pm 1.46\%$ dans l'ensemble de test et un temps de calcul égal **0.32** seconde.

Pour améliorer les performances de notre système d'authentification des visages. Nous proposons d'utiliser les filtres de Gabor au lieu d'utiliser l'information des pixels comme caractéristiques des visages et utiliser la fusion des scores issus de plusieurs experts.

BIBLIOGRAPHIE

- [1] R. Hietmeyer, Biometric *identification* promises fast and secure processing of airline passengers. The International Civil Aviation Organization Journal, Vol. 17, No. 9, pp. 10–11, 2000.
- [2] T. Kanade, Picture Processing System by Computer Complex and Recognition of Human **Faces**. In: Doctoral dissertation, *Kyoto University*, November 1973.
- [3] Daniel L. Ruderman. The statistics of natural images. *Network: Computation in Neural Systems*, pages 517_548., 1994.
- [4] Penev,P., and Atick,J. Local Feature Analysis: A General Statistical Theory for Object Representation. *Network Computational. Neural System* 7,477-500, 1996.
- [5] Anour Mellakh, Reconnaissance des visages en conditions dégradées. Thèse de doctorat préparée au Département Électronique et Physique de l'Institut National des Télécommunications dans le cadre de l'École Doctorale SITEVERY en co-accreditation avec l'université d'Evry-Val d'Essonne. 2009.
- [6] M. Turk, A. Pentland, Eigenfaces for recognition. *J. of Cognitive Neuroscience* 3, 72–86, 1991.
- [7] Anis CHAARI, Nouvelle approche d'identification dans les bases de données biométriques basée sur une classification non supervisée. Pour obtenir le diplôme du doctorat Spécialités Sciences pour l'ingénieur et Informatique, 2009.
- [8] Chengjun Liu and Harry Wechsler , Gabor Feature Based Classification Using the Enhanced Fisher Linear Discriminant Model for Face Recognition. *IEEE Trans. Image Processing*, vol. 11, no. 4, pp. 467-476, 2002.
- [9] Xiaoxun Zhang, Yunde Jia, A linear discriminant analysis framework based on random subspace for face Recognition, *Elsevier Pattern Recognition* 40 2585 – 2591, (2007)
- [10] Hua Yu and Jie Yang. A Direct LDA algorithm for high-dimensional data with application to face recognition. *Pattern Recognition*, 34(10): 2067_ 2070, 2001.
- [11] T. P. Minka, Automatic choice of dimensionality of pca. Technical Report TR 514, MIT Media Laboratory Perceptual computing section, 2000.
- [12] Muriel Visani, Vers de nouvelles approches discriminantes pour la reconnaissance automatique de visages. Thèse de doctorat de l'Institut National des

- Sciences Appliquées de Lyon Spécialité Informatique, 25 Novembre 2005
- [13] Vladimir N. Vapnik. The nature of statistical learning theory. *Springer Verlag New York, Inc, New York, NY, USA, 1995.*
- [14] Lorène Allano. La Biométrie multimodale : stratégies de fusion de scores et mesures de dépendance appliquées aux bases de personnes virtuelles. Thèse présentée pour l'obtention du grade de Docteur de l'institut national des télécommunications 2009.
- [15] K. Messer, J. Matas, J. Kittler, J.Luettin, and G. Maitre, XM2VTSDB: The Extended M2VTS Database. In Proceedings, International Conference on Audio- and Video-Based Person Authentication. 72–77, 1999.
- [16] Nicolas MORIZET, Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris. Thèse présentée pour obtenir le grade de Docteur de l'Ecole Nationale Supérieure des Télécommunications Spécialité : Signal et Images, 2009.
- [17] Mohammad T. Sadeghi, Samaneh Khoshrou, and Josef Kittler. Confidence Based Gating of Colour Features for Face Authentication. Springer-Verlag Berlin Heidelberg, pp. 121–130, 2007.
- [18] Wonjun Hwang, Haitao Wang, Hyunwoo Kim, *Member, IEEE*, Seok-Cheol Kee, and Junmo Kim, *Member, IEEE*. Face Recognition System Using Multiple Face Model of Hybrid Fourier Feature under Uncontrolled Illumination Variation. *IEEE Transactions on image processing* 2011.
- [19] D.Saigaa, Application des Réseaux de Neurone et de la Logique Floue à l'Authentification d'Individus par Reconnaissance de Visages, Département d'Automatique Université Mohamed Khider Biskra Algérie. Courrier du Savoir – N°06, Juin 2005, pp.61-66
- [20] Shuicheng Yan, *Member, IEEE*, Jianzhuang Liu, *Senior Member, IEEE*, Xiaou Tang, *Senior Member, IEEE*, and Thomas S. Huang, *Life Fellow, IEEE*, Formulating Face Verification With Semidefinite Programming. *IEEE Transactions on image processing*, Vol. 16, N° 11, November 2007.
- [21] Irene Kotsia, Stefanos Zafeiriou, and Ioannis Pitas, *Fellow, IEEE*, A Novel Discriminant Non-Negative Matrix Factorization Algorithm With Applications to Facial Image Characterization Problems. *IEEE Transactions on information forensics and security*, Vol 2, N° 3, Semptember 2007.
- [22] Pascual Ejarque, Javier Hernado, David Hernando, and David Gómez, Eigenfeatures and Supervectors
- [23] in Feature and Score Fusion for SVM Face and Speaker Verification. Springer-Verlag Berlin Heidelberg, pp. 81–88, 2009
- [24] Fahimeh Salimi, Mohammad Sadeghi, Mohammad S. Moin, and Josef Kittler, Face Verification Using Colour Kernels. Springer-Verlag Berlin Heidelberg, pp. 522–531, 2009
- [25] M.Belahcène, A. AbdElMalik, A. Ahmed Taleb Fusion by combination of scores multi-biometric systems EUVIP'11 Juillet 2011 Paris 13.