

Authentification et Identification de Visages basées sur les Ondelettes et les Réseaux de Neurones.

M.BELAHCENE-BENATIA Mébarka.
LI3C Univ.Med Khider.BISKRA

Résumé : Notre but est de concevoir un système d'authentification d'identité qui soit facile et peu coûteux dans l'implémentation utilisant une modalité biométrique particulière (le visage humain). Notre application contient deux classes : à savoir d'une part les clients et d'autre part les imposteurs de la base de données **XM2VTS**. Notre étude est basée sur la **DWT** associée à l'**ACP** d'une part et aux réseaux de neurones d'autre part. Les taux d'erreurs ont été calculés dans deux ensembles d'abord dans un ensemble d'évaluation, qui va permettre de fixer plus ou moins le **TEE** en faisant varier les paramètres d'acceptation et de rejet du système. Ensuite dans un ensemble de test en utilisant les paramètres fixés précédemment. Ainsi, on peut vérifier la robustesse du système d'authentification. Nous avons utilisé deux méthodes de classification associées à l'**ACP** : i) classification basée sur la mesure de similarité qui nous donne des résultats fonctionnant dans le domaine de haute sécurité. D'après les résultats obtenus **L1** et **L2** s'avèrent les meilleures distances pour la discrimination entre le client et l'imposteur dans le cas de **L1 TEE = 11.5** pour un nombre de paramètres caractéristiques **Np= 40** avec un **TFA= 9** et un **TFR=15.32**. En utilisant la distance **L2 TEE=12.72** pour un **Np= 80**, avec un **TFA=30** et **TFR= 11.56**. ii) Nous avons aussi utilisé le réseau de neurones pour la classification et des résultats plus satisfaisants ont été obtenus. Nous arrivons à un **TFA = 5** et un **TFR= 57** et avec la normalisation un **TFA = 12** et un **TFR = 23** pour un **Np = 60**

Mots clés :

Authentification, Identification, Ondelettes (DWT), ACP, Classification, TEE, Réseaux de neurones.

1. Introduction

L'histoire compte plusieurs tentatives de reconnaissance de visages [1,2,3,4,7,9]. Celles-ci souffrent de deux inconvénients principaux. Le premier est que le temps d'exécution du processus de reconnaissance est très grand et le deuxième c'est un taux d'erreurs élevé surtout dans le domaine de l'auto identification en temps réel. Parmi ces méthodes : i) **Méthodes géométriques** : méthodes locales ou analytiques basées sur les paramètres géométriques courants pour la détection automatique de caractéristiques. Ces méthodes ne fournissent pas un degré élevé d'exactitude et exigent une capacité de calcul considérable Parmi celles-ci on cite : méthode des objets (Eigen Object), modèle de Markov (HHM: Hidden Markov Models) ; ii) **Méthodes globales** : cette méthode utilise le visage en complet comme source d'information et sans segmentation de ses parties. Parmi ces méthode on cite : les visages propres (Eigen

Faces), la DCT (Discret Cosinus Transform), Réseau de Neurones(RN), Analyse Discriminante Linéaire LDA (Linear Discriminant Analysis) ; Analyse en composante principale (ACP),

Analyse en Composante Indépendantes (ACI), Machines à Vecteurs de Support (SVM) etc...L'objectif de notre étude est de concevoir un modèle d'authentification et d'identification des visages basé sur l'analyse en ondelettes associée à l'ACP d'une part et les réseaux de neurones d'autre part.

2. Présentation du modèle

La performance des modèles dépend fortement de la qualité des résultats de détection et de normalisation des visages. Cela veut dire que plus la précision obtenue est élevée, plus les conditions (d'acquisition, d'éclairage, pose etc.) se rapprocheront de celles de la phase d'apprentissage, ce qui donne une authentification efficace. Dans notre étude les images de la base de données XM2VTS sont lues, découpées puis analysées par la transformation en ondelettes et ensuite projetées sur les sous espaces de l'ACP. Finalement, elles sont classifiées par calcul de distances ou par réseau de neurones.

Pour cela nous suivons les étapes suivantes : 1. *Prétraitement et analyse par ondelette discrète (ondelette de Haar)* ; 2. *Normalisation des matrices (si nécessaire)* ; 3. *L'utilisation de la méthode ACP* ; 3. *Similitude par calcul des distances puis réseau de neurones* ; 4. *Décision*.

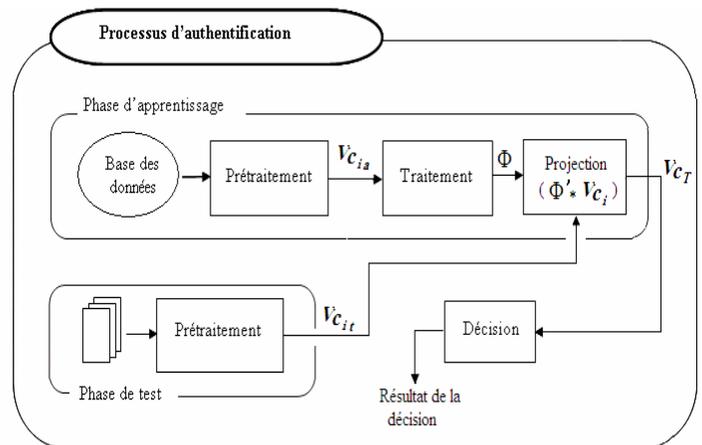


Figure 1 Schéma d'un Système d'Authentification de Visages.

2.1. Les ondelettes en imagerie

L'idée est simple, comme tout filtre appliqué à une image, il suffit de multiplier les coefficients de l'ondelette (après l'avoir discrétisée) par la valeur des pixels de l'image à traiter. On notera que l'ondelette peut alors être représentée sous la forme d'un tableau (de dimension 1) de valeurs décimales. En réalité il y a 2 tableaux qui représentent l'ondelette car une ondelette se compose de 2 filtres : un passe-bas et un passe-haut. Voici ci-dessous les coefficients de l'ondelette de Haar discrétisée :

Ondelette de Haar :

Passe-Bas : [0.71; 0.71]; Passe-Haut : [-0.71; 0.71]

2.2. Le vecteur descripteur

À partir des attributs extraits de l'image, on construit un vecteur caractéristique, c'est le **vecteur descripteur** de l'image. Ce vecteur descripteur contient les attributs intéressants extraits de l'image. Il se présente en général sous la forme d'un vecteur à n composantes réelles. Les attributs extraits des images sont de différents types et sont exprimés dans des unités différentes selon qu'ils appartiennent à la couleur, la texture ou la forme. Une étape de **normalisation** est parfois indispensable, elle va permettre de réajuster les valeurs des attributs pour les rendre commensurables.

2.3 Définition d'analyse en composantes principales

L'analyse en composantes principales (ACP) est une transformation linéaire basée sur les méthodes statistiques classiques. L'analyse en composantes principales est une méthode qui a pour but de déterminer un sous-espace « optimale » pour la compression et la reconstruction de données. Elle peut s'appliquer au cas où le vecteur de donnée dans l'espace primaire est composé d'un grand nombre de caractéristiques. La projection des images en utilisant l'ACP est un procédé standard pour beaucoup d'aspects basés sur des algorithmes d'identification d'objet. Une explication de base de projection dans l'espace propre (EigenSpace) est fournie par. **Michael Kirby**[9] était le premier à présenter l'idée du bas dimensionnel pour des images de visage. **Turk et Pentland** [10] ont travaillé avec la projection d'**EigenSpace** pour l'identification de visages

❖ Algorithme général

Une image peut être regardée comme un vecteur de pixels où la valeur de chaque entrée dans le vecteur est le niveau de gris du pixel correspondant. Par exemple, une image 8x8 peut être traitée comme un vecteur de longueur 64. On dit que

2

l'image repose dans N dimensionnel d'espace, où N est le nombre de pixels (ou la longueur du vecteur). Ce vecteur représente l'image considérée dans l'espace original. La majorité des sous-espaces, y compris les espaces propres (**EigenSpace**), n'optimisent pas les caractéristiques de discrimination. **EigenSpace** optimise la variance des images.

❖ Espace de projection par la méthode ACP

L'espace de projection est trouvé en identifiant les vecteurs propres de la matrice de covariance dérivée d'un ensemble d'images d'apprentissage. Les vecteurs propres (ou visages propres) correspondant aux valeurs propres non nulles de la matrice de covariance forment une base orthogonale. Spécifiquement, dans cette approche, l'image à deux dimensions d'un visage est transformée en un vecteur de taille N obtenu en enchaînant les lignes (ou colonnes) de l'image correspondante. Ici N représente le nombre de pixels dans l'image du visage.

$$x^i = \begin{bmatrix} \vec{x}_1^i & \vec{x}_2^i & \dots & \vec{x}_N^i \end{bmatrix}^T \quad (1)$$

x^i : Matrice des vecteurs image ; x_j : Vecteur d'image

Toutes les images sont centrées en soustrayant l'image moyenne de chaque vecteur image :

$$\bar{x}^i = x^i - m \quad \text{où} \quad m = \frac{1}{p} \sum_{i=1}^p x^i \quad (2)$$

Ces vecteurs sont combinés, côte à côte, pour créer une matrice de données d'apprentissages de taille NxP (où P est le nombre d'images).

$$\bar{X} = [\bar{x}^1 \ \bar{x}^2 \ \bar{x}^3 \ \dots \ \bar{x}^p] \quad (3)$$

La matrice de données \bar{X} est multipliée par sa transposée pour trouver la matrice de covariance.

$$\Omega = \bar{X}\bar{X}^T \quad (4)$$

Cette matrice de covariance a P vecteurs propres liés aux valeurs propres non nulles, assurant $P < N$. Les vecteurs propres sont classés dans l'ordre décroissant, selon leurs valeurs propres associées. Le vecteur propre lié à la plus grande valeur propre représente la variance maximale des vecteurs images d'apprentissage. Le vecteur propre lié à la deuxième plus grande valeur propre représente la deuxième variance maximale des vecteurs images d'apprentissage. Cette tendance continue jusqu'à ce que la plus petite valeur propre soit associée au vecteur propre qui représente la moindre variance des vecteurs images d'apprentissage.

❖ **Identification des images en utilisant l'espace propre**

L'identification des images par la projection dans l'espace propre prend trois mesures de base. D'abord l'espace propre doit être créé en utilisant des images d'apprentissage. Après, les images d'apprentissage sont projetées dans l'espace propre. Finalement, les images de test sont identifiées en les projetant dans l'espace propre puis comparées aux images projetées d'apprentissage.

❖ **Création de l'espace propre**

Pour créer un espace propre on utilise les étapes suivantes :

a) **Centrer les données** : Chacune des images d'apprentissage doit être centrée.

b) **Créer la matrice de données** : Une fois que les images d'apprentissage sont centrées, elles sont combinées dans une matrice de données de la taille NxP

c) **Créer la matrice de covariance**: La matrice de données est multipliée par sa transposée pour créer une matrice de covariance comme montré dans l'équation (4).

d) **Calculer les valeurs propres et les vecteurs propres**: Les valeurs propres et les vecteurs propres correspondants à la matrice de covariance sont calculés par la relation suivante:

$$\Omega V = \Delta V \quad (5)$$

Où V est une matrice orthogonale de vecteurs propres et Δ et une matrice diagonale de valeurs propres.

e) **Ordonner les vecteurs propres** : Classer les vecteurs propres $v_i \in V$ selon leurs valeurs propres décroissantes $\lambda_i \in \Delta$. Maintenir seulement les vecteurs propres liés aux valeurs propres différentes de zéro. Cette matrice des vecteurs propres V représente l'espace propre de projection où chaque colonne de V est un vecteur propre.

$$V = \begin{bmatrix} \vec{v}_1 & \vec{v}_2 & \dots & \vec{v}_i & \dots & \vec{v}_p \end{bmatrix} \quad (6)$$

f) **Projeter les images d'apprentissage** : Chacun des vecteurs images centrés d'apprentissage (x_i) est projeté dans l'espace propre. Pour projeter un vecteur image dans l'espace propre, on doit calculer le produit scalaire de ce vecteur image avec la transposée de la matrice V formée par les vecteurs propres selon la relation suivante :

$$\tilde{x}^i = V^T \bar{x}^i \quad (7)$$

Par conséquent, le produit scalaire de l'image et du premier vecteur propre sera la première valeur dans le nouveau

vecteur. Le nouveau vecteur de l'image projetée \tilde{x}^i contiendra les coefficients de projection du vecteur image \bar{x}^i dans l'espace propre.

g) **Identifier les images de test** : Chaque image de test y^i est premièrement centrée en soustrayant l'image moyenne, et puis projetée dans le même espace propre défini par V . Ceci est montré par les deux équations suivantes :

$$\bar{y}^i = y^i - m \quad \text{où} \quad m = \frac{1}{p} \sum_{i=1}^p x^i \quad (8)$$

$$\tilde{y}^i = V^T \bar{y}^i \quad (9)$$

L'image projetée de test est comparée à l'image projetée d'apprentissage. Les images peuvent être comparées en utilisant l'une des mesures de similitude; la plus connue la norme L2.

2. 4 La classification

La classification consiste à organiser un ensemble de données multidimensionnelles en un **ensemble fini de classes** selon un ou plusieurs **critère(s) de classification** à l'aide d'un **classifieur**.

2.5 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. Elle est basée sur un **seuil** prédéfini. L'estimation du seuil de la décision constitue la plus grande difficulté de ces techniques, et elle peut engendrer deux types d'erreurs, souvent prises comme mesures de performances pour ces techniques d'authentification: faux rejet (**FR**) et fausse acceptation (**FA**). Bien sûr, un système d'authentification idéal est celui qui donne $FA=FR=0$. Malheureusement, dans les conditions réelles, ceci est impossible. Par conséquent, un compromis doit être fait dans le choix du seuil, et ce dernier est très dépendant de l'application.

$$TFR = \frac{\text{nombre de clients rejetés}(FR)}{\text{nombre des clients totale}} \quad (10)$$

$$TFA = \frac{\text{nombre de imposteur accepté}(FA)}{\text{nombre des imposteur totale}} \quad (11)$$

$$TET = \frac{\text{nombre de fausse d'acceptation}(FA) + \text{nombre de fausse de rejeté}(FR)}{\text{nombr totale d'accès}} \quad (12)$$

$$TS = 1 - TET \quad (13)$$

3-Application du modèle

Pour la conception du modèle nous avons choisi l'environnement de travail MATLAB 7.1

3.1) Présentation des procédures du programme

1) Procédure d'apprentissage

En premier lieu, nous procédons à la lecture des images de la base de données d'apprentissage. Ces images sont prétraitées, transformées en N/B puis nous les décomposons par l'ondelette de **Haar** ce qui donne quatre sous images : image approximée, détail vertical, détail horizontal et détail diagonal de taille (33x33). L'approximée de chaque image est retenue pour l'étude puis convertie en vecteur. Nous mettons ensuite tous les vecteurs des images dans une matrice appelée **mat**. Celle-ci est ensuite projetée en sous espace par l'ACP dans le but de minimiser sa taille afin de réduire le nombre de paramètres caractéristiques sans perte d'information. Finalement, une matrice des vecteurs propres **poo** est obtenue de taille (C=600, L = selon la taille choisie des vecteurs propres). La base de données apprentissage présente 200 images de personnes différentes (3 images différentes pour chaque personne). Ensuite, la base de donnée client évaluation **clvset** est lue et nous effectuons le même travail précédent. Nous obtenons ainsi une matrice **oi** de même taille que **poo**. Le calcul de la distance entre **poo** et **oi** est alors effectué. La **distance_intra maximale** est retenue. Deuxièmement, la base de donnée **impevset** est lue et prétraitée puis projetée et après la projection nous obtenons une matrice **y** (C=200, L = selon la taille du vecteur propre). Pour les imposteurs évaluation **impevset** il y a 25 classes à huit images c'est-à-dire 200 images. Nous calculons dans ce cas la distance entre chaque image de **impevset** avec chaque classe de **trset** et on prend le minimum, finalement matrice de (200*200) distances est obtenue, la **distance_extra** retenue est le **minimum** des ces distances. Enfin, le seuil est calculé comme la somme de **dist_intra** et **dist_extra** sur deux.

2) Procédure de test

Les images test (clients test et les imposteurs test) sont soumises au modèle, on obtient une matrice contenant 497 vecteur pour les imposteurs et 400 pour les clients. Nous projetons les vecteurs dans une même base d'apprentissage puis le calcul des distances est effectué et on prend le meilleur vecteur propre et le seuil est calculé pour trouver TFA et TFR.

4

3) Classification par mesure de similarité

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 l'ensemble d'évaluation est utilisé. Deux distances sont calculées :

-La distance_intra(**d_intra**) : La distance entre deux images de visage de même individu.

-La distance_extra(**d_extra**) : La distance entre deux images de visage de deux individus différents.

Théoriquement : (**max**(distance_intra) < **min**(distance_extra))

Dans cette condition, il est possible de déterminer un seuil S qui détermine une classification correcte.

Il suffit de prendre :

$$S = (\max(d_intra) + \min(d_extra)) / 2 \quad (14)$$

Malheureusement cette situation ne se rencontre que très rarement en pratique. Donc, nous devons choisir un critère à minimiser pour fixer le seuil de manière à atteindre le TEE souhaité.

4) Le taux de faux rejets et le taux de fausses acceptations

Dans notre cas, le problème qui nous préoccupe contient deux classes, les clients et les imposteurs. Les concepteurs de technologies biométriques sont contraints de faire un compromis en gardant le **TFA** à un niveau plus haut que souhaité afin de garder un **TFR** acceptable. Et le juste milieu se situe quelque part entre les deux, et si les coûts des erreurs sont égaux, il se trouvera au taux d'égale erreur ou **TEE**, c'est à dire quand **TFR=TFA**. Dans un système de contrôle d'accès critique, on préférera souvent un **TFA** plus faible que le **TFR**. Lorsque le **TEE** ne peut être atteint, on utilise une mesure similaire qui est le demi taux d'erreur total, ou **HTER** c'est en fait la moyenne de **TFA** et du **TFR**. Tous les taux d'erreurs sont calculés dans deux des trois ensembles: d'abord dans l'ensemble d'évaluation, ce qui va permettre de fixer plus ou moins le **TEE** en faisant varier les paramètres d'acceptation et de rejet du système. Ensuite dans l'ensemble de test en utilisant les paramètres fixés précédemment. Il est possible de vérifier la robustesse du système. Si les chiffres dans les deux ensembles sont proches, le système est stable.

4. Application et résultats

Les étapes de base de la méthode sont :

4.1-**Conversion** de la couleur en niveaux

de gris.

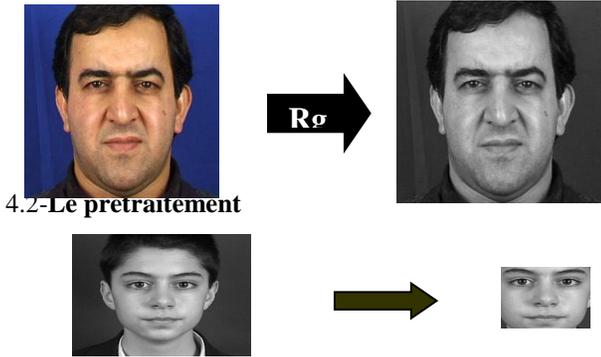


Figure 2 Représentation de la conversion et du découpage
4.3-Décomposition par l'ondelette de Haar

Pour la conception et la validation de notre modèle nous utiliserons dans un premier temps l'image approximée qui n'est autre que l'image originale filtrée et décimée. La figure suivante représente l'effet de l'ondelette de Haar sur l'image originale.



Figure 3 L'effet de l'ondelette de Haar

4.5- Projection sur l'espace ACP

Les premiers vecteurs propres (visages propres) de notre première expérience sont donnés par la figure suivante :



Figure 4 Eigenfaces (ACP Faces)

Nous projetons les images dans un sous espace de différentes dimensions de (1 jusqu'à 200). Le vecteur image X_i se transforme en vecteur Y_i par la relation :

$$Y_i = V^T \times X_i \tag{15}$$

$V^T : (V_1, V_2, \dots, V_i, V, \dots, V_{200})$.

$V_i, i=1, \dots, 200$: sont les vecteurs propres.

4.6 Résultats

Après application du modèle nous obtenons les résultats suivants :

4.6. A Classification par mesure de similarité

1. Phase d'apprentissage

(N_p : Nombre de paramètres caractéristiques)

Tableau 1 TEE en fonction du N_p

5

N_p	10	40	60	80	100	120	150	170	200
L1	12.8	11.5	12	12.5	13	14	14.55	14.61	14.97
L2	13	11.3	12.40	12.62	12.70	13.50	14.00	14.09	14.99
Mah	45.5	37.5	36.1	35.8	35.2	35	34.8	34.24	34
Cor	77.9	78.0	78.4	77.9	77.8	77.33	77.5	77.2	77.1

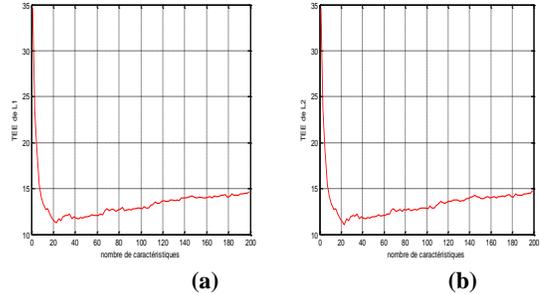


Figure 5 TEE en fonction du N_p normes a) L1 b) L2

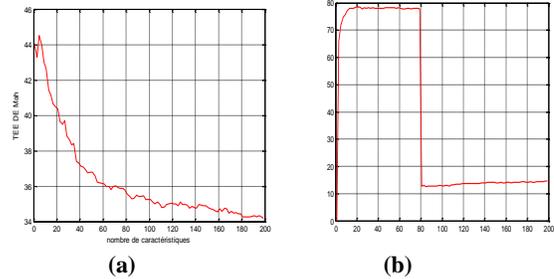


Figure 6 TEE en fonction du N_p normes a) Mahalanobis b) corrélation

D'après les résultats obtenus L1 et L2 s'avèrent les meilleures distances pour la discrimination entre le client et l'imposteur dans le cas de L1 nous obtenons **TEE = 11.5** pour un nombre de paramètres caractéristiques $N_p = 40$ avec un **TFA=9** et un **TFR=15.32**. En utilisant la distance L2 **TEE=12.72** pour un nombre de paramètres de caractéristiques = **80**.

2. Phase de test

Dans toutes les expériences précédentes menées sur la base d'évaluation nous avons fixé le seuil de telle manière à obtenir un taux d'erreur égal (TEE), nous procédons à l'étude de la stabilité de notre système en basant nos expériences sur la base de données test en utilisant le seuil fixé précédemment. Le seuil donnant le meilleur TFR et TFA est retenu. Les résultats obtenus avec ces paramètres sont présentés dans les tableaux suivants :

a) Sans normalisation Pour $N_p=80$

Tableau 2 Variation du TFA et TFR pour différentes distances. (sans normalisation).

	TFA	TFR
L1	10	88.3
L2	1.5	88.3
Mahalon.	50	92.35

Nous remarquons que les taux d'erreur en utilisant la mesure de similitude par la norme L1 et L2 sont très proches. Le TFA reste stable dans les deux ensembles évaluation et test par contre la variation du TFR est très grande entre les deux ensembles évaluation et test ce qui rend le système instable. Dans ce cas, le modèle a rejeté un fort taux de clients et a accepté un faible taux d'imposteurs. Donc on peut dire que le modèle ainsi conçu reconnaît correctement les imposteurs, mais il présente des difficultés à identifier les clients. Nous tentons d'améliorer le TFA par la technique de la normalisation.

b) Avec normalisation : Pour Np=150

Tableau 3 Variation du TFA et TFR pour les normes L1 et L2 (avec normalisation).

	TFA	TFR
L1	9.8	77
L2	14.55	86.56

Lorsque nous normalisons les matrices des vecteurs à la sortie de l'ondelettes, nous remarquons une légère différence pour Np = 150 dans le cas de L1 TFA = 9.8. On peut dire qu'aucune amélioration nette n'a été apportée par la normalisation et les meilleurs paramètres restent ceux obtenus pour L2 avec NB=80 Aussi, lorsque TFR>TFA, le modèle fonctionne dans la zone de haute sécurité. Ce qui est sollicité dans les banques et autres domaines de haute sécurité Toujours dans le souci d'améliorer nos résultats nous avons essayé d'appliquer le modèle conçu à une des images de détails (la meilleure sur le plan qualité visuelle). Mais aucune amélioration n'a été constatée, aussi, nous jugeons bon de ne pas présenter ces résultats.

4.6.B Classification par réseau de neurone

Pour classifier les individus nous attribuons aux deux sorties

du RN $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ pour le client et $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ pour l'imposteur.

1 Classification par perceptron multicouches

C'est une extension du Perceptron qui a une ou plusieurs sous-couches cachées. Dû à sa structure étendue, un Perceptron multicouches est capable de résoudre toute opération logique incluant le problème XOR. La méthode d'apprentissage est supervisée. L'algorithme d'apprentissage est la règle d'apprentissage Delta qui affecte le changement des poids en multipliant l'entrée d'un neurone avec la différence de la sortie et de la sortie désirée et le taux d'apprentissage du réseau. Nous avons un problème à deux

classes, pour cela nous suivons les étapes suivantes et la première étape est l'apprentissage du réseau de neurone
1 - Les entrées du réseau de neurones sont les distances des clients issues de l'apprentissage de XM2VTS.

2 - Fixation des targettes (les sorties désirées) selon la taille du réseau et la taille d'entrée

3 - Création du net en déterminant les paramètres de couche d'entrée et la couche cachée

4 - Détermination de la fonction d'activation comme: **tansig**, **logsig**, et **purelin**.

5 - L'entraînement du réseau par l'instruction **train**.

6 - Simulation finale.

Nous faisons varier dans les vecteurs propres et nous évaluons les courbes des erreurs

2 Rétro propagation par gradient

Ce type de réseau est l'un de plus puissants réseaux de neurone. Il a la même structure que le perceptron multicouches et utilise l'algorithme de rétro propagation. La méthode d'apprentissage est supervisée.

Architecture du réseau

Le réseau présenté ici présente les caractéristiques suivantes :

-Il comporte une seule couche d'entrée

-Il comporte une seule couche de sortie.

-Il peut comporter une ou plusieurs couches cachées.

-Chaque neurone est uniquement relié à tous les neurones de la couche suivante.

La fonction de transfert est sigmoïde.

1. Phase d'apprentissage

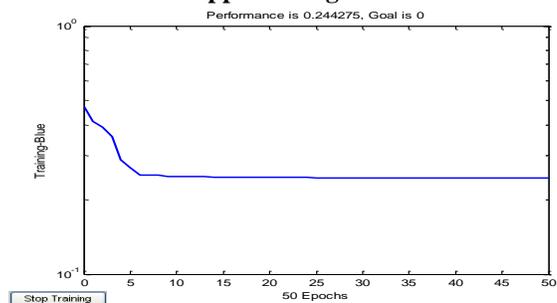


Figure 7 Courbe de variation des erreurs en fonction du nombre d'itération

On observe à partir des résultats que l'erreur diminue avec l'augmentation du nombre d'itération. Lorsqu'on varie dans les vecteurs propres la performance augmente :

Perf=moy (t-y)^2 Tel que **perf: la moyenne des erreurs**

Tel que : (t) c'est la sortie désiré et (y) c'est la sortie du réseau de neurone.

2. Phase de test

Dans la partie de test on détermine l'entrée à tester:

-On teste avec l'entrée Sim (net, entré).

-On vérifie le résultat si égale à un donc un client, si égale à zéro c'est un imposteur.

Les taux d'erreur TFA et TFR pour différentes normes : **L1, L2 et Mahalanobis.**

Tableau 4 Sans normalisation

Pour **Np =60**

	L1		L2		Mah	
	TFA	TFR	TFA	TFR	TFA	TFR
Evaluation	20	70	13	78	18	70
Test	10	89	5	57	66	84

Tableau 5 Avec normalisation

	L1		L2		Mah	
	TFA	TFR	TFA	TFR	TFA	TFR
Evaluation	15	38	19	88	80	76
Test	12	23	15	44	78	84

De nettes améliorations sont obtenues relativement à la classification précédente. Nous arrivons à un **TFA = 5** et un **TFR= 57** pour un **Np = 60** et avec la normalisation un **TFA = 12** et un **TFR = 23** pour un **Np = 60**. Nous pouvons dire que le réseau de neurones associé aux ondelettes donne de meilleurs résultats que la classification par similarité. En plus ça nous évite de calculer le seuil et son choix très délicat, car probablement les valeurs de **TFA** et **TFR** obtenues auparavant sont dûes à un mauvais choix du seuil .

5 Conclusion

Nous avons utilisé deux méthodes de classification par mesure de similarité à base d'ACP qui nous donne des résultats fonctionnant dans le domaine de haute sécurité. D'après les résultats obtenus L1 et L2 s'avèrent les meilleures distances pour la discrimination entre le client et l'imposteur dans le cas de L1 **TEE = 11.5** pour un nombre de paramètres caractéristiques NB = 40 avec un **TFA= 9** et un **TFR=15.32**. En utilisant la distance L2 **TEE=12.72** pour un nombre de paramètres de caractéristiques = 80, avec un **TFA=30** et **TFR= 11.56**. Nous avons aussi utilisé le réseau de neurones pour la classification, des résultats satisfaisants sont obtenus. De nettes améliorations sont obtenues relativement à la classification précédente. Nous arrivons à un **TFA = 5** et un **TFR= 57** pour un **NB = 60** et avec la normalisation un **TFA = 12** et un **TFR = 23** pour un **NB = 60**. Nous pouvons dire que le réseau de neurones associé aux ondelettes donne de meilleurs résultats que la classification par similarité. En plus ça nous évite de calculer le seuil et son choix très délicat, car probablement les valeurs de **TFA** et **TFR** obtenus auparavant sont dûs à un mauvais choix du seuil. Mais ceci n'est pas sans inconvénients nous

7

citons quelques uns: le réseau de neurones détermine ses paramètres aléatoirement, variation des erreurs...

Pour ces raisons notre travail pourrait s'améliorer dans le cas de l'ACP, chercher une méthode d'évaluation automatique du seuil et utiliser plusieurs résolution des ondelettes (trois résolution), essayer de normaliser les entrées du réseau de neurones afin d'obtenir des valeurs comprises entre 0 et 1 et essayer la classification par réseau de neurones de Kohonen.

Remerciements :

Je tiens à remercier Mrs Y. TOUAHRI et A.TOUNSI pour leur contribution.

Références bibliographiques

- [1] B.Hadj Ali et S.Mohamed Réseaux de neurones -Théorie et pratique OPU,ALGERIE,12-2005.
- [2] Marc Parizeau Réseaux de neurones GIF-21140 et GIF-64326. Université LAVAL, Automne 2004 (lien Internet).
- [4] C.Liu and H.Weschler. Evolutionary pursuit and its application to face recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence,22(6):570-582,June 2000
- [5] W.Mc Culloch, W.Pitts A logical calculus of the ideas immanent in nervous activity . Bulletin of Mathematical Biophysics, 1943.
- [6] M. Belahcene Benatia, Analyse de textures. Mémoire de Magister en Electronique. Université de Batna, Octobre 1994.
- [7] B.Moghaddam and A.Pentland. Face recognition using view-based and modular eigenspaces. Automatic Systems for Identification and Inspection of Humans, SPIE,2277, July 1994.
- [8] M.A.Mellakh Thèse de doctorat Option telecommunication INT Paris2009
- [9] L.Sirovitch et M.Kirby. A Low-Dimensional Procedure for the Characterization of Human Faces. Journal of Optical Society of America, 4(3): 519-524 1987.
- [10] M.Turk and A.Pentland. Eigenfaces for Recognition. Journal of Cognitive Neuroscience,3(1):71-86,1991.
- [11] Michal Spanel, Pavel Zemcik Face Representation and Tracking Using Gabor Wavelet Network. Brno University of Technology, Faculty of Information Technology. Computer Graphics and Multimedia Department

M.Belahcene-Benatia Mebarka

[12] Dr. Tai Sing Lee Image Representation Using 2D Gabor Wavelets. Professor in the Department of Computer Science at Carnegie Mellon University and in the CMU-University of Pittsburgh Center of Neural Basis of Cognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, October 1996.

[13] Vivien Chappelier, Christine Guillemot, Slavica Marinkovi Codage d'image par ondelettes unidimensionnelles orientées. IRISA/Université de Rennes I, Campus de Beaulieu, 35042 RENNES

[14] M. Belahcène K.Parker Roméo Z.Baarir. « *Analyse de textures par ACP* ». Université de Batna. Département électronique. 1994.

[15] Walid Hizem, « *Capteur Intelligent pour la Reconnaissance de Visage* », Thèse présentée pour l'obtention du diplôme de Docteur de l'institut national des Télécommunications. Doctorat délivré conjointement par L'Institut National des Télécommunications et l'Université Pierre et Marie Curie - Paris 6.Spécialité : Electronique/Informatique.

[16] Souhila Guerfi Ababsa, *Authentification d'individus par reconnaissance de caractéristiques biométriques liées aux visages 2D/3D*, THÈSE pour obtenir le titre de Docteur de l'Université Evry Val d'Essonne Spécialité: Sciences de l'Ingénieur université d'Evry val d'Essonne, 2008

[17] Réda Jourani, *Reconnaissance de visages*, mémoire pour l'obtention du Diplôme des Etudes Supérieures Approfondies, Université Mohammed V-Agdal , Novembre 2006.

[18] Nicolas Morizet, *Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris*, présentée pour obtenir le grade de Docteur, École Doctorale d'Informatique, Télécommunications et Électronique de Paris, Mars 2009.

[19] C. Rouabhia, J. Khellil & H. Tebbikh , Laboratoire d'Automatique et Informatique de Guelma –LAIGU Université 8 mai 45. BP 402,Article, Guelma c_rouabhia@yahoo.fr ,2009. _

[20] Ch.Rouabhia,A/H.BoualagetH.Tebbikh, Approche Bidimensionnelle Hybride Neuro-ACPDL2D pour la Reconnaissance Automatique de Visages.Laboratoire d'Automatique et Informatique de Guelma -LAIG -Université de Guelma, Algérie