

Une Nouvelle Méthode de Représentation des Visages pour leur Reconnaissance : l'Analyse Discriminante Bilinéaire

Muriel Visani, Christophe Garcia
France Telecom Division R&D TECH / IRIS
4, rue du Clos Courtel
35512 Cesson-Sevigne, France

{muriel.visani,christophe.garcia}@rd.francetelecom.com

Jean-Michel Jolion
Laboratoire LIRIS, INSA Lyon
20, Avenue Albert Einstein
Villeurbanne, 69621 cedex, France

Jean-Michel.Jolion@insa-lyon.fr

Résumé

Dans cet article, nous présentons une nouvelle technique de reconnaissance de visages nommée Analyse Discriminante Bilinéaire (ADB). Cette méthode repose sur la maximisation d'un critère de Fisher généralisé basé sur une projection bilinéaire des matrices-images des visages. Cette approche généralise celle d'Analyse Discriminante Linéaire 2D Orientée (ADL2Do), que nous avons précédemment introduite. Les résultats de classification obtenus sur des bases internationales montrent la complémentarité des deux méthodes issues de l'ADL2Do, et le fait que l'ADB allie les pouvoirs discriminants de ces deux techniques tout en étant plus performante que chacune d'elles prise séparément. Une évaluation poussée de la méthode proposée montre la supériorité de celle-ci sur les techniques usuelles.

Mots clefs

Reconnaissance de visages, représentation de visages, extraction de caractéristiques, analyse discriminante.

1 Introduction

Durant les vingt dernières années, la reconnaissance automatique de visages est devenue un enjeu primordial, notamment dans les domaines de la sécurité et de l'indexation de documents multimédia. Malgré la multitude de techniques proposées et les progrès réalisés [1], le problème reste non résolu, comme le montre la récente évaluation menée par le *National Institute of Standards and Technology* (NIST) [2]. Les difficultés proviennent essentiellement de la forte variabilité des données à classer (dues à des changements dans l'expression faciale, dans la pose de la tête, dans les conditions d'illumination et à des occultations partielles), et dans le fait que les images de visages constituent des données de très grandes dimensions.

Comme toute tâche de reconnaissance de formes, le processus de reconnaissance automatique de visages se décompose en deux étapes : l'extraction d'éléments caractéristiques (appelés *signatures*) et la classification de ceux-ci.

Depuis les travaux de Sirovitch et Kirby [3], démontrant l'efficacité de l'Analyse en Composantes Principales (ACP) pour la représentation des visages, les techniques de projection statistique ont été très utilisées dans le contexte de la reconnaissance de visages. Parmi les techniques les plus connues, on compte les méthodes dites des *Eigenfaces* [4] et des *Fisherfaces* [5], consistant respectivement à appliquer une ACP et une ACP suivie d'une Analyse Discriminante Linéaire (ADL) sur des vecteurs-images de très grandes dimensions. Ces derniers sont obtenus par concaténation des lignes (ou des colonnes) des valeurs de pixels des images de visages. Ces analyses de données en très grandes dimensions sont coûteuses en temps de calcul, et souffrent d'instabilité numérique. Pour pallier ces inconvénients, Yang *et al.* ont introduit dans [6] la technique d'Analyse en Composantes Principales bidimensionnelle (ACP2D), plus performante et robuste aux différentes sources de variabilité que la méthode des *eigenfaces* [7]. Cependant, la technique non-supervisée sous-jacente, à savoir l'ACP, est plus adaptée à la représentation des visages qu'à leur classification, à l'inverse de l'ADL. Nous avons donc proposé l'Analyse Discriminante Linéaire Bidimensionnelle Orientée (ADL2Do), plus efficace et robuste que la méthode des *fisherfaces* et que l'ACP2D [8]. Comme nous le détaillerons en section 2, l'ADL2Do se décline en deux versions, et selon les bases de visages considérées, la meilleure des deux n'est pas toujours la même. Choisir entre ces deux versions nécessite donc une analyse qualitative préalable des bases d'apprentissage et de test, ce qui est une tâche difficile et coûteuse en temps de calcul. C'est pourquoi nous introduisons ici la méthode d'Analyse Discriminante Bilinéaire (ADB), qui constitue un mode de combinaison efficace de ces deux techniques. L'ADB allie le pouvoir discriminant de l'ADL et la stabilité de la modélisation bidimensionnelle, tout en réduisant la dimension des signatures par rapport à l'ACP2D et à l'ADL2Do. Cet article est organisé comme suit. En section 2, nous décrivons rapidement les deux méthodes issues de l'ADL2Do, avant de montrer la complémentarité de celles-ci et d'introduire la technique d'ADB. En section 3, nous

présentons des résultats d'expérimentations mettant en évidence la supériorité de l'ADB sur les deux versions de l'ADL2Do (et par conséquent sur les *fisherfaces* [8]), et sur l'ACP2D (et donc sur les *eigenfaces* [6, 7]). Nous concluons cet article en section 4.

2 De l'ADL2Do à l'ADB

On dispose d'une base de connaissance Ω contenant n images de visages en niveaux de gris, avec plus d'une vue par personne. L'ensemble des images correspondant à une même personne est désigné par le terme de *classe*. La base de connaissance contient C classes. Chaque image est stockée sous la forme d'une matrice de pixels de taille $h \times w$, et sa classe d'appartenance Ω_c est connue.

2.1 L'ADL2Do

L'ADL2Do se décline en deux versions : l'ADL2D orientée en lignes (ADL2DoL), que nous avons proposée dans [8], et 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 :

$$X_i^P = X_i P \quad (1)$$

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 :

$$P^* = \underset{P \in \mathbb{R}^{w \times k}}{\text{Argmax}} \frac{|P^T S_b P|}{|P^T S_w P|} \quad (2)$$

est un classifieur de Bayes optimal, où S_w et S_b sont respectivement les *matrices de covariance intra et inter classes généralisées* de Ω :

$$S_w = \sum_{c=1}^C \sum_{X_i \in \Omega_c} (X_i - \bar{X}_c)^T (X_i - \bar{X}_c) \quad (3)$$

$$S_b = \sum_{c=1}^C n_c (\bar{X}_c - \bar{X})^T (\bar{X}_c - \bar{X}) \quad (4)$$

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 (on peut aisément montrer que cette hypothèse est généralement vérifiée), 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 :

$$X_i^Q = Q^T X_i, \quad (5)$$

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 :

$$Q^* = \underset{Q \in \mathbb{R}^{h \times k}}{\text{Argmax}} \frac{|Q^T \Sigma_b Q|}{|Q^T \Sigma_w Q|} \quad (6)$$

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

$$\Sigma_w = \sum_{c=1}^C \sum_{X_i \in \Omega_c} (X_i - \bar{X}_c)(X_i - \bar{X}_c)^T \quad (7)$$

$$\Sigma_b = \sum_{c=1}^C n_c (\bar{X}_c - \bar{X})(\bar{X}_c - \bar{X})^T. \quad (8)$$

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.

Pour l'ADL2DoL comme pour l'ADL2DoC, le nombre k de vecteurs propres à retenir peut être déterminé grâce au critère de Wilks Lambda [9]. La classification se fait à l'aide d'une règle du plus proche voisin entre signatures selon la distance Euclidienne.

2.2 Complémentarité de l'ADL2DoL et de l'ADL2DoC

Dans cette partie, nous présentons les résultats d'expérimentations mettant en lumière la complémentarité des deux méthodes définies ci-dessus. Les visages sont centrés dans les images, et celles-ci sont redimensionnées à une taille suffisante de $h \times w = 75 \times 65$ pixels.

Nous utilisons la base de visages de Yale [5], qui contient 15 personnes et 11 vues par personne (voir Figure 1). Ces vues présentent des occultations partielles, ainsi que des dissimilarités dans les conditions d'éclairage et les expressions faciales.

Dans la première expérimentation, la base de Yale est divisée aléatoirement en une base d'apprentissage contenant quatre vues par personne, et une base de test contenant six vues par personne. Pour favoriser l'homoscédasticité, on regroupe toutes les vues similaires (p. ex., les 15 vues « Surprise » sont contenues soit dans la base d'apprentissage, soit dans la base de test). Cette opération est répétée cinq fois ; les matrices de confusion correspondantes, calculées avec $k = 14$, sont présentées dans le Tableau 1. L'élément noté (a) dans la matrice (1) correspond au nombre de visages reconnus par les deux




Figure 1 – Extraits : (a) de la base d'apprentissage et (b) des sept bases de test. Pour une personne donnée, si les vues de la base d'apprentissage sont non occultées alors la base « Occultation » contient une vue avec lunettes, et inversement.

méthodes. L'élément (b) est le nombre de visages reconnus par l'ADL2DoL, mais mal classés par l'ADL2DoC ; l'élément (c) est le nombre de visages reconnus par l'ADL2DoC, mais mal classés par l'ADL2DoL. En (d), on trouve le nombre de visages mal classés par les deux méthodes. Les matrices (2-5) sont agencées de la même manière. Le Tableau 1(1) montre que, pour la première partition considérée, les performances de deux méthodes sont comparables : les taux de reconnaissance sont respectivement $\frac{53+10}{53+10+11+16} = 70\%$ et $71,1\%$ pour l'ADL2DoL et l'ADL2DoC. Cependant, on peut noter que les résultats de classification sont très différents : 21 visages (23,3% de la base d'apprentissage) sont reconnus par une méthode seulement. On peut également noter que $82,2\% \gg \max(70\%, 71,1\%)$ des visages sont reconnus par au moins l'une des deux méthodes. Les matrices de confusion (2-3) illustrent le fait que, généralement, l'ADL2DoL est plus performante que l'ADL2DoC. On peut remarquer que, dans ce cas, le taux de visages mal classés simultanément par les deux méthodes est faible (3,3% pour la partition (2) et 6,7% pour la (3)). Les matrices de confusion (4-5) montrent que, dans certains cas où le taux de visages mal classés par les deux méthodes est plus important ($\frac{16}{90} = 17,8\%$ et 20% pour les partitions (4) et (5)), l'ADL2DoC est significativement plus performante que l'ADL2DoL. Par conséquent, selon les caractéristiques des bases d'apprentissage et de test considérées, la méthode la plus performante n'est pas nécessairement la même.

La deuxième expérimentation fournit une analyse qualitative plus poussée. La base d'apprentissage, illustrée en Figure 1(a), contient quatre vues pour chacune des 15 personnes, avec des variations dans les conditions d'illumination et les expressions faciales. Puis, sept bases de test sont construites (voir Figure 1(b)), à partir des vues restantes. La Figure 2 donne une comparaison des performances de l'ADL2DoL et de l'ADL2DoC, sur ces sept bases de test.

53 (a)	10 (b)	71	11	72	8	55	5	63	2
11 (c)	16 (d)	5	3	4	6	14	16	7	18
(1)	(2)	(3)	(4)	(5)					

Tableau 1 – Matrices de confusions de cinq partitions aléatoires de la base de Yale.




Figure 2 – Taux de reconnaissance comparés de l'ADL2DoL et de l'ADL2DoC, sur sept partitions de la base de Yale.

On constate que l'ADL2DoL est généralement plus performante que l'ADL2DoC. Cependant, dans certains cas, l'ADL2DoC est significativement plus performante que l'ADL2DoL, notamment quand la base de test contient des dissymétries selon l'axe vertical (p. ex. les vues « Lumière Gauche » et « Lumière Droite »). L'ADL2DoC peut également donner des résultats légèrement meilleurs si le changement d'expression faciale est très important, par exemple pour les vues « Surprise ». Le choix de la version de l'ADL2Do la plus adaptée au problème requiert donc une phase préliminaire d'analyse qualitative des bases utilisées, ce qui constitue une tâche difficile. Une autre voie est de combiner efficacement ces deux méthodes pour en créer une troisième, moins dépendante des bases et au moins aussi performante que la meilleure des deux méthodes dont elle est issue ; nous introduisons dans la section ci-après une telle technique.

2.3 L'Analyse Discriminante Bilinéaire

Considérons deux matrices de projection $Q \in \mathbb{R}^{h \times k}$ et $P \in \mathbb{R}^{w \times k}$, et la projection bilinéaire suivante :

$$X_i^{Q,P} = Q^T X_i P \quad (9)$$

où la matrice $X_i^{Q,P}$, de taille $k \times k$, constitue la signature associée par l'ADB au visage X_i . Le couple optimal (Q^*, P^*) de matrices de projection maximise la séparation entre les signatures issues de classes différentes tout en minimisant la distance entre les signatures issues d'une même classe. On peut donc considérer le critère de Fisher généralisé suivant :

$$(Q^*, P^*) = \underset{(Q,P) \in \mathbb{R}^{h \times k} \times \mathbb{R}^{w \times k}}{\text{Argmax}} \frac{|S_b^{Q,P}|}{|S_w^{Q,P}|} \quad (10)$$

$$= \text{Argmax} \frac{|\sum_{c=1}^C n_c (\overline{X_c^{Q,P}} - \overline{X^{Q,P}})^T (\overline{X_c^{Q,P}} - \overline{X^{Q,P}})|}{|\sum_{c=1}^C \sum_{i \in \Omega_c} (X_i^{Q,P} - \overline{X_c^{Q,P}})^T (X_i^{Q,P} - \overline{X_c^{Q,P}})|} \quad (11)$$

où $S_w^{Q,P}$ et $S_b^{Q,P}$ sont respectivement les matrices de covariance intra et inter classes de la base constituée des $(X_i^{Q,P})_{i \in \{1, \dots, n\}}$; la matrice $\overline{X_c^{Q,P}}$ est la signature

moyenne des visages de Ω_c , et $\overline{X^{Q,P}}$ est la signature moyenne, calculée sur Ω . La fonction objectif (11) est bi-quadratique et n'a pas de solution analytique. Nous proposons donc une procédure itérative baptisée *Analyse Discriminante Bilineaire*. Développons l'expression (11) :

$$(Q^*, P^*) = \underset{P}{\operatorname{Argmax}} \frac{|\sum_{c=1}^C n_c P^T (\overline{X_c} - \overline{X})^T Q Q^T (\overline{X_c} - \overline{X}) P|}{|\sum_{c=1}^C \sum_{i \in \Omega_c} P^T (X_i - \overline{X_c})^T Q Q^T (X_i - \overline{X_c}) P|} \quad (12)$$

Pour toute matrice $Q \in \mathbb{R}^{h \times k}$ fixée, le critère (11) peut donc être reformulé de la manière suivante :

$$P^* = \underset{P \in \mathbb{R}^{w \times k}}{\operatorname{Argmax}} \frac{|P^T [\sum_c n_c (\overline{X_c^Q} - \overline{X^Q})^T (\overline{X_c^Q} - \overline{X^Q})] P|}{|P^T [\sum_{c=1}^C \sum_{i \in \Omega_c} (X_i^Q - \overline{X_c^Q})^T (X_i^Q - \overline{X_c^Q})] P|} \quad (13)$$

$$= \underset{P \in \mathbb{R}^{w \times k}}{\operatorname{Argmax}} \frac{|P^T S_b^Q P|}{|P^T S_w^Q P|} \quad (14)$$

où S_w^Q et S_b^Q correspondent respectivement aux matrices de covariance intra et inter classes généralisées de la base des matrices $(X_i^Q)_{i \in \{1 \dots n\}}$ (cf. équation (5)). Par conséquent, les colonnes de la matrice P^* sont les k vecteurs propres de la matrice $S_w^Q^{-1} S_b^Q$ correspondant aux plus grandes valeurs propres.

Etant donné que, pour toute matrice carrée A , on a $|AA^T| = |A^T A|$, et si l'on pose $A = P^T (\overline{X_c} - \overline{X})^T Q$ (matrice de taille $k \times k$), on obtient :

$$(Q^*, P^*) = \underset{Q}{\operatorname{Argmax}} \frac{|\sum_c n_c Q^T (\overline{X_c} - \overline{X}) P P^T (\overline{X_c} - \overline{X})^T Q|}{|\sum_c \sum_{i \in \Omega_c} Q^T (X_i - \overline{X_c}) P P^T (X_i - \overline{X_c})^T Q|} \quad (15)$$

Par conséquent, pour toute matrice $P \in \mathbb{R}^{w \times k}$ fixée, le critère (11) peut s'écrire :

$$Q^* = \underset{Q \in \mathbb{R}^{h \times k}}{\operatorname{Argmax}} \frac{|Q^T \Sigma_b^P Q|}{|Q^T \Sigma_w^P Q|} \quad (16)$$

Σ_w^P et Σ_b^P étant les matrices de covariance intra et inter classes généralisées de la base des matrices $((X_i^P)^T)_{i \in \{1 \dots n\}}$, obtenues par transposée des projections des X_i sur P (selon (1)). Les colonnes de Q^* sont donc constituées des k vecteurs propres de la matrice $(\Sigma_w^P)^{-1} \Sigma_b^P$ correspondant aux plus grandes valeurs propres.

Notons que la taille des signatures issues de l'ADB (en l'occurrence $k \times k$), est plus réduite que pour l'ACP2D ($h \times k$), l'ADL2DoL ($h \times k$) et l'ADL2DoC ($w \times k$).

Deux algorithmes itératifs sont envisagés pour mettre en œuvre l'ADB. Le premier nécessite de fixer *ad hoc* le nombre k de vecteurs propres (on peut pour cela utiliser une stratégie de type *leave-one-out* par exemple); le second peut être qualifié de *procédure descendante*, puisqu'à chaque itération le nombre de composantes retenues est réduit.

Algorithme 1

On initialise $P_0 = I_w$, où I_w est la matrice identité de taille $w \times w$. Le nombre k de vecteurs propres est fixé.

Pour t allant de 1 à T

1. $\forall i \in \{1, \dots, n\}$, on calcule $X_i^{P_{t-1}} = X_i P_{t-1}$;
2. On calcule $\Sigma_w^{P_{t-1}}, \Sigma_b^{P_{t-1}}$ et $(\Sigma_w^{P_{t-1}})^{-1} \Sigma_b^{P_{t-1}}$;
3. On construit la matrice Q_t , dont les colonnes sont les k premiers vecteurs propres de $(\Sigma_w^{P_{t-1}})^{-1} \Sigma_b^{P_{t-1}}$;
4. Pour tout $i \in \{1, \dots, n\}$, on calcule $X_i^{Q_t} = Q_t^T X_i$;
5. On calcule $S_w^{Q_t}, S_b^{Q_t}$, et $(S_w^{Q_t})^{-1} S_b^{Q_t}$;
6. On construit la matrice P_t , dont les colonnes sont les k premiers vecteurs propres de $(S_w^{Q_t})^{-1} S_b^{Q_t}$;

Fin Pour

Le nombre d'itérations T peut être déterminé de la manière suivante : on considère qu'il y a convergence si les changements des matrices P et Q sont inférieurs à un certain seuil, c.-à-d. $\sqrt{(\|P_T - P_{T-1}\|_2^2 + \|Q_T - Q_{T-1}\|_2^2)} < \tau$, où τ peut être déterminé à l'aide d'une stratégie de validation croisée par exemple. Cependant, les résultats expérimentaux ont montré qu'après seulement une itération les performances de l'algorithme sont très satisfaisantes. Par conséquent, dans la suite, nous utiliserons cet algorithme avec une seule itération.

Algorithme 2

Initialisons $t = 1, P_0 = I_w$ et $k_1 = w$.

1. $\forall i \in \{1, \dots, n\}$, on calcule $X_i^{P_{t-1}} = X_i P_{t-1}$;
2. On calcule $\Sigma_w^{P_{t-1}}, \Sigma_b^{P_{t-1}}$ et $(\Sigma_w^{P_{t-1}})^{-1} \Sigma_b^{P_{t-1}}$;
3. On construit la matrice Q_t , dont les colonnes sont les k_t premiers vecteurs propres de $(\Sigma_w^{P_{t-1}})^{-1} \Sigma_b^{P_{t-1}}$;
4. Pour tout $i \in \{1, \dots, n\}$, on calcule $X_i^{Q_t} = Q_t^T X_i$;
5. On calcule $S_w^{Q_t}, S_b^{Q_t}$, et $(S_w^{Q_t})^{-1} S_b^{Q_t}$;
6. On construit la matrice P_t , dont les colonnes sont les k_t premiers vecteurs propres de $(S_w^{Q_t})^{-1} S_b^{Q_t}$;
7. Si $t = 1, t \leftarrow t+1, k_t \leftarrow k_{t-1} - 1$, et retourner à l'étape 1.;
8. Sinon, si $t \geq 2$, test de Wilks-Lambda :
 - Si H_0 , alors $t \leftarrow t+1, k_t \leftarrow k_{t-1} - 1$, et retourner à l'étape 1.;
 - Sinon $k \leftarrow k_{t-1}, Q \leftarrow Q_{t-1}$ et $P \leftarrow P_{t-1}$.

Le critère d'arrêt (étape 8.) est basé sur le critère de Wilks Lambda, permettant de tester le pouvoir discriminant des $w - k_t$ derniers vecteurs propres de $(S_w^{Q_t})^{-1} S_b^{Q_t}$. Considérons le test reposant sur l'hypothèse nulle H_0 : « aucun des vecteurs propres $k_t + 1, \dots, w$ n'a de pouvoir discriminant » et sur l'hypothèse alternative H_1 : non H_0 . Sous l'hypothèse H_0 , on peut montrer que la statistique de test suit une loi de de Wilks; sa *p-valeur* (choisie à un niveau de confiance de 5%) peut être estimée à l'aide de l'approximation de Bartlett (approximation de la loi de Wilks par une loi du χ^2). Si le test conclut à la validité de l'hypothèse H_0 , les derniers vecteurs propres peuvent être rejetés et l'on passe à l'itération suivante. Sinon, au moins l'un des derniers vecteurs propres apporte une information discriminante et ne doit pas être rejeté.



Figure 3 – Extraits de la base de visages ORL.

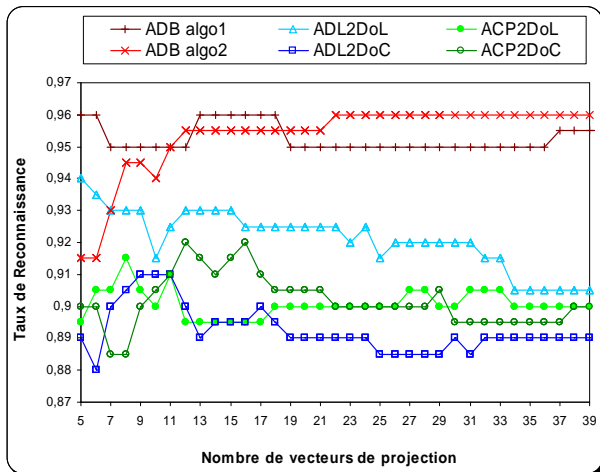


Figure 4 – Taux de reconnaissance estimés sur la partition (1) des six méthodes, en fonction du nombre k de vecteurs propres retenus.

3 Résultats Expérimentaux

Dans cette section, nous présentons des résultats expérimentaux montrant l'efficacité de l'ADB et sa supériorité sur l'ADL2Do et l'ACP2D. Les expérimentations sont menées sur la base ORL [10], contenant 40 personnes, et dont un extrait est donné en Figure 3. Diverses sources de variabilité sont représentées dans cette base : on observe notamment des variations dans la pose de la tête, dans l'échelle du visage, dans l'expression faciale et dans les conditions d'illumination. Les images, initialement de taille 112×92 , sont normalisées de manière à être centrées sur le visage et redimensionnées à une taille suffisante de 50×50 pixels.

La base est divisée aléatoirement en deux sous-bases : l'une servant pour l'apprentissage, l'autre pour le test. Cette opération est répétée six fois. Une fois les signatures des images provenant des deux bases extraites, nous appliquons une simple règle du plus proche voisin selon la distance Euclidienne. La Figure 4 donne les taux de reconnaissance comparés de l'ADB, de l'ADL2DoL, de l'ADL2DoC et de l'ACP2D, pour la première partition aléatoire. Yang *et al.* [6] ont introduit la version orientée en lignes de l'ACP2D (notée ici ACP2DoL). Par analogie avec la définition de l'ADL2DoC (cf. section 2.1), nous définissons et évaluons l'ACP2D orientée en co-

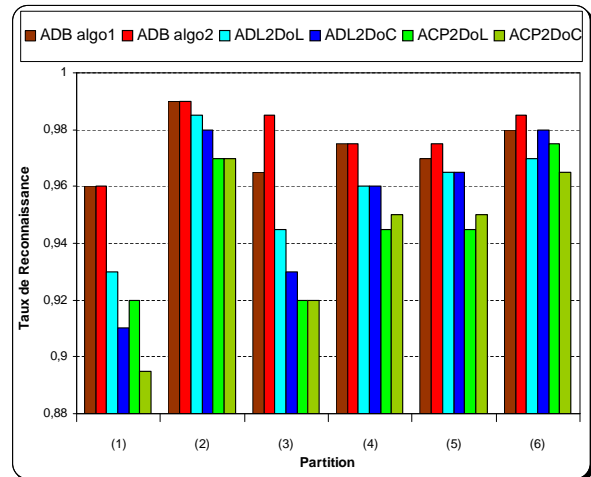


Figure 5 – Taux de reconnaissance comparés, de gauche à droite, de l'ADB1, de l'ADB2, de l'ADL2DoL, de l'ADL2DoC, de l'ACP2DoL et de l'ACP2DoC, pour chacune des six partitions aléatoires d'ORL considérées.

lonne, notée ici ACP2DoC. Notons la supériorité de l'ADB sur les autres méthodes, ceci indépendamment de l'algorithme (1 ou 2) utilisé. Dans un souci de simplicité, dans la suite l'ADB suivant l'algorithme 1 est désigné par l'acronyme *ADB1*, tandis que pour l'algorithme 2 on utilise l'acronyme *ADB2*. La Figure 4 montre que les performances des deux algorithmes sont comparables pour la partition (1), mais l'ADB2 nécessite un nombre k de composantes plus élevé que l'ADB1 ($k = 25$ pour l'ADB2 contre $k = 6$ pour l'ADB1). Remarquons également que l'ADL2DoL est plus performante que l'ACP2DoC et l'ACP2DoL, comme nous l'avons déjà souligné dans [8]. La figure 5 fournit une comparaison des taux de reconnaissance des six méthodes évaluées, pour les six partitions aléatoires considérées. Nous pouvons noter que l'ADB (indépendamment de l'algorithme considéré), est toujours plus performante que la meilleure des deux méthodes issues de l'ADL2Do, elle-même étant plus performante que l'ACP2DoL et l'ACP2DoC. Notons également que l'algorithme 2 de l'ADB semble donner de légèrement meilleurs résultats que l'algorithme 1.

La première ligne du Tableau 2 présente les matrices de confusion des deux versions de l'ADL2Do, comme décrit en section 2.2. La deuxième ligne donne les matrices de confusion de l'ADB1 avec l'ADL2DoL et de l'ADL2DoC, pour chacune des partitions envisagées. L'élément (e) correspond au nombre de visages bien classés par les trois méthodes. Le nombre visages bien classés par l'ADB1 et l'ADL2DoL, mais mal classés par l'ADL2DoC est donné en (f). En (g), on trouve le nombre de visages reconnus par l'ADB1 et l'ADL2DoC, mais mal classés par l'ADL2DoL. L'élément (h) est le nombre de visages qui sont reconnus par l'ADB1, mais qui ne sont reconnus par aucune des deux versions de l'ADL2Do. Dans la deuxième

177 ^(a)	9 ^(b)	196	1	181	8	190	2	187	6	193	1
5 ^(c)	9 ^(d)	0	3	5	6	2	6	6	1	3	3
176 ^(e)	7 ^(f)	196	1	181	6	186	2	187	5	190	0
3 ^(g)	6 ^(h)	0	1	2	4	2	5	2	0	3	3
177 ⁽ⁱ⁾	7 ^(j)	196	1	181	7	187	2	187	4	190	1
3 ^(k)	5 ^(l)	0	1	5	4	1	5	3	1	3	3
(1)	(2)	(3)	(4)	(5)	(6)						

Tableau 2 – Matrices de confusions de six partitions aléatoires de la base ORL.

ligne on retrouve les matrices de confusion de l'ADB2 avec l'ADL2DoL et de l'ADL2DoC, agencées de la même manière. On peut remarquer que, pour toutes les partitions étudiées et indépendamment de l'algorithme utilisé, l'ADB reconnaît la quasi-totalité des visages reconnus par les deux versions de l'ADL2Do (resp. $\frac{176+196+181+186+187+190}{177+196+181+190+187+193} = 99,3\%$ et $99,5\%$ pour l'ADB1 et l'ADB2, en moyenne sur les six partitions). On note également que l'ADB reconnaît la majeure partie des visages qui étaient reconnus par une seule des deux méthodes (respectivement 62,5% et 68,8% pour ADB1 et l'ADB2). Ces résultats montrent l'efficacité de l'ADB comme mode de fusion des deux méthodes de l'ADL2Do. L'ADB, tout en garantissant de très bons résultats de classification, amène donc une certaine stabilité par rapport au choix des bases de visages utilisées, en comparaison avec l'ADL2Do. Il faut également noter que l'ADB reconnaît une importante partie (67,9% en moyenne sur les six partitions, quel que soit l'algorithme choisi) des visages qui n'étaient reconnus par aucune des deux méthodes issues de l'ADL2Do, ce qui montre que l'ADB est plus efficace que l'ADL2Do.

4 Conclusion

Dans cet article, nous avons introduit une nouvelle technique de reconnaissance de visages, appelée Analyse Discriminante Bidimensionnelle (ADB). Nous avons précédemment introduit l'ADL2Do, qui se décline en deux versions : l'ADL2DoL et l'ADL2DoC. Dans un premier temps, nous avons montré la complémentarité de ces deux versions et le fait que, selon les bases de visages considérées, la meilleure des deux n'est pas toujours la même. Nous avons donc introduit l'ADB, qui généralise le concept d'ADL2Do par l'utilisation d'un mode de projection bilinéaire. L'ADB se décline sous la forme de deux algorithmes itératifs, dont l'un utilise un nombre de vecteurs de projection fixés *ad hoc*, et l'autre consiste en un rejet pas à pas des vecteurs statistiquement les moins discriminants. Les résultats expérimentaux montrent que l'ADB allie les pouvoirs discriminants des deux versions issues de l'ADL2Do, qu'elle est plus performante que chacune de ces deux méthodes prise séparément et que la technique d'ACP2D.

Les distributions des classes dans l'espace des signatures obtenues par ADB ont un comportement très favorable à la classification. Dans l'approche proposée dans cet article, les signatures de visages sont classées à l'aide d'une distance Euclidienne au plus proche voisin. Une prochaine étape de notre travail consistera en l'utilisation d'autres classificateurs dans l'espace de l'ADB, dans le but de diminuer le coût calculatoire de la phase de classification et d'instaurer des règles permettant le rejet des visages non enregistrés dans la base de connaissance.

Références

- [1] W. Zhao, R. Chellappa, P.J. Phillips et A. Rosenfeld. Face recognition : A literature survey. *ACM Computing Survey*, 35(4) :399–458, 2003.
- [2] P.J. Phillips, P. Grother, R.J. Micheals, D.M. Blackburn, E. Tabassi et J.M. Bone. Face Recognition Vendor Test 2002. Evaluation Report. Technical Report 6965, NIST, Mars 2003.
- [3] 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.
- [4] M.A. Turk et A.D. Pentland. Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, 3(1) :71–86, 1991.
- [5] P.N. Belhumeur, J.P. Hespanha et D.J. Kriegman. Eigenfaces vs Fisherfaces : Recognition Using Class Specific Linear Projection. *IEEE Trans. on PAMI*, 19(7) :711–720, 1997.
- [6] J. Yang, D. Zhang et A.F. Frangi. Two-Dimensional PCA : A New Approach to Appearance-Based Face Representation and Recognition. *IEEE Trans. on PAMI*, 26(1) :131–137, 2004.
- [7] M. Visani, C. Garcia et C. Laurent. Comparing Robustness of Two-Dimensional PCA and Eigenfaces for Face Recognition. Dans *Proc. of the Int. Conf. on Image Analysis and Recognition ICIAR'04, Springer LNCS 3211, A. Campilho, M. Kamel (eds)*, pages 717–724, Porto, Portugal, Octobre 2004.
- [8] M. Visani, C. Garcia et J.M. Jolion. Two-Dimensional-Oriented Linear Discriminant Analysis for Face Recognition. Dans *Proc. of the Int. Conf. on Computer Vision and Graphics ICCVG'04, à paraître dans la série Computational Imaging and Vision*, Varsovie, Pologne, Septembre 2004.
- [9] G. Saporta. *Probabilités, Analyse de données et Statistique*. Editions Technip, 1990.
- [10] F. Samaria et A. Harter. Parameterisation of a Stochastic Model for Human Face Identification. Dans *Proc. of the IEEE Workshop on Applications of Computer Vision*, Sarasota, Floride, Décembre 1994.