



HAL
open science

Évaluation de la qualité de données biométriques morphologiques

Mohamad El-Abed, Christophe Charrier, Christophe Rosenberger

► **To cite this version:**

Mohamad El-Abed, Christophe Charrier, Christophe Rosenberger. Évaluation de la qualité de données biométriques morphologiques. colloque COmpression et REprésentation des Signaux Audio-visuels (CORESA), May 2012, Lille, France. 6 p. hal-00806229

HAL Id: hal-00806229

<https://hal.science/hal-00806229>

Submitted on 2 Apr 2013

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Évaluation de la qualité de données biométriques morphologiques

Mohamad El-Abed, Christophe Charrier et Christophe Rosenberger
Université de Caen Basse-Normandie, UMR 6072 GREYC, F-14032 Caen, France
ENSICAEN, UMR 6072 GREYC, F-14050 Caen, France
CNRS, UMR 6072 GREYC, F-14032 Caen, France

Résumé

L'évaluation de la qualité des données biométriques est très importante dans la mesure où celle-ci permet d'améliorer la performance d'un système biométrique. Nous présentons dans cet article une méthode pour quantifier la qualité de données biométriques morphologiques. Elle est basée sur l'utilisation conjointe de deux types d'informations : 1) la qualité de l'image, et 2) la qualité des paramètres extraits en utilisant le descripteur SIFT. L'approche proposée possède l'avantage d'être plurimodale (visage, empreinte digitale et veines de la main), et indépendante du système de vérification utilisé. Nous avons montré l'intérêt de la méthode proposée pour détecter plusieurs types d'altérations réelles des données qui ont un impact majeur sur la performance globale des systèmes biométriques.

Mots clefs

Biométrie, Évaluation, Qualité, BLINDS, SIFT

1 Introduction

Les systèmes d'authentification basés sur la biométrie sont beaucoup moins précis que ceux basés sur *ce que l'on sait* ou *ce que l'on possède*. Contrairement aux systèmes traditionnels, la comparaison de deux vecteurs biométriques est exprimée en pourcentage de similarité qui n'atteint quasiment jamais 100%. Cette variation des résultats est plutôt liée aux artefacts d'acquisition qu'à l'échantillon biométrique de l'individu qui est généralement stable avec le temps. Prenons le cas des systèmes d'authentification par empreintes digitales : la qualité d'image de l'empreinte peut varier selon le degré de saleté de la peau du doigt, son niveau d'humidité, son aspect huileux ou son aspect dégradé (*ex.*, coupure). La pression que l'on exerce sur le capteur utilisé est aussi déterminante quant aux détails qui sont recueillis. Ainsi, pour qu'un système soit opérationnel et efficace contre les divers types de bruit d'acquisition, contrôler la qualité des données acquises devient indispensable.

L'évaluation de la qualité des données biométriques est un domaine de recherche récent en biométrie. Les travaux effectués sur la qualité sont très peu abordés

par rapport aux recherches telles que l'extraction de paramètres, la reconnaissance, *etc.* La plupart de ces travaux sont dépendants de la modalité utilisée [1, 2, 3, 4, 5, 6, 7, 5, 8] et du système de vérification. Prenons, par exemple, les travaux de Zhang et Wang [7]. Les auteurs ont présenté une méthode basée sur l'hypothèse d'asymétrie du visage. La méthode utilise le descripteur SIFT pour quantifier la qualité d'une image, et est basée sur l'utilisation de trois métriques de qualité : q_1 mesure le rapport des points SIFT détectés sur les deux côtés du visage, q_2 et q_3 ajoutent les critères de localisation et des descripteurs SIFT sur les points d'intérêt détectés, respectivement. La méthode présentée a démontré sa robustesse face aux variations d'éclairage et de pose. Cependant, elle ne peut pas être utilisée pour les autres types de modalité (comme l'empreinte digitale). D'autres méthodes [9] basées sur la distribution des scores des utilisateurs légitimes et d'imposteurs ont été développées et requièrent un certain nombre d'images pour chaque classe, ce qui limite leur utilisation d'une manière directe sur les images acquises. Nous proposons dans cet article une nouvelle approche pour quantifier la qualité de données biométriques morphologiques. Cette approche est basée sur l'utilisation conjointe de deux types d'informations : 1) la qualité de l'image, et 2) la qualité des paramètres extraits en utilisant le descripteur SIFT [10]. L'approche proposée possède l'avantage d'être plurimodale (visage, empreinte digitale et veines de la main), et indépendante du système de vérification utilisé.

Dans la suite de cet article, la Section 2 décrit l'approche retenue, et la Section 3 son protocole d'évaluation. Les résultats expérimentaux sont donnés dans la Section 4. Enfin, la Section 5 conclut cet article.

2 Méthode développée

La méthode proposée consiste à quantifier la qualité d'une donnée biométrique en utilisant deux types d'informations complémentaires (*cf* Figure 1). Le principe retenu est le suivant : suite au calcul d'un critère de qualité d'image (Section 2.1) et de plusieurs critères de qualité du descripteur (Section 2.2), un processus de classification par apprentissage statistique est opéré à

partir de l'ensemble des critères calculés (Section 2.3).




Figure 1 – Principe de la méthode proposée.

2.1 Qualité image sans référence

L'évaluation de la qualité des images est classiquement utilisée pour valider un traitement appliqué sur des images numériques. Dans le cadre de la compression des images, par exemple, une telle évaluation est utilisée pour quantifier la qualité de l'image reconstruite. Les métriques de qualité sont généralement classées en trois catégories : 1) les métriques de qualité avec référence complète, notées FR (*Full Reference*), qui comparent l'image à évaluer avec un modèle de référence de celle-ci ; 2) les métriques de qualité avec référence réduite, notées RR (*Reduced Reference*), qui comparent une description de l'image à évaluer avec une description du modèle de référence ; et 3) les métriques de qualité sans référence, notées NR (*No Reference*), qui quantifient la qualité de l'image à évaluer, à partir de connaissances a priori sur celles-ci (*i.e.*, sans utilisation de modèle ou de description de référence). Dans cette étude, étant donné que le signal de référence n'est pas disponible, nous avons cherché à utiliser une métrique de qualité sans référence (NR). La plupart des métriques NR existantes dépendent de l'artefact d'acquisition (effet de bloc, flou, *etc.*), ce qui limite leur utilisation en pratique. D'autres méthodes [11, 12] utilisent un algorithme d'apprentissage sur des paramètres extraits. L'efficacité de ces métriques dépend ainsi de la fiabilité et de la généralisation de ces paramètres. Dans cet article, nous avons utilisé l'indice *BLind Image Integrity Notator using DCT Statistics* (BLIINDS) [13] qui ne dépend pas de l'artefact d'acquisition. Cet indice exploite la notion des statistiques de scènes naturelles. L'idée principale de cette approche repose sur l'hypothèse que les fonctions du système visuel humain ont évolué en fonction du temps et sont adaptées aux statistiques du monde dans lequel l'être humain évolue. L'indice BLIINDS est basé sur le calcul de quatre facteurs de dégradation dans le domaine de la DCT à différentes résolutions spatiales de l'image. Ces facteurs sont ensuite combinés afin de calculer la note finale de qualité. L'image est décomposée en bloc de taille 17×17 . Les dégradations mesurées sont :

1. Distorsion de contraste (v_1). Le contraste est une propriété intrinsèque d'une image qui désigne la

différence entre les zones claires et foncées d'une image. Le contraste v_1 est calculé en utilisant les valeurs de contraste local de chaque bloc. Le contraste local du k -ième bloc est donné par :

$$c^k(x) = \frac{1}{N} \sum_{i=1}^N \frac{x_{AC}^i}{x_{DC}} \quad (1)$$

avec N est la taille du bloc, x_{DC} représente le coefficient DC et l'ensemble $\{x_{AC}^i | i = 1 : N\}$ représente les coefficients AC . Le contraste de l'image v_1 est ainsi calculé par :

$$v_1 = \frac{1}{M} \sum_{i=1}^M c^i(x) \quad (2)$$

avec M est le nombre de blocs de l'image en question.

2. Distorsion de structure (v_2). Les caractéristiques de structure sont obtenues en utilisant le kurtosis des coefficients (non DC) de fréquences DCT, calculés sur chaque bloc. Le kurtosis du $k^{\text{ème}}$ bloc est donné par :

$$\kappa^k(x_{AC}) = \frac{E(x_{AC} - \mu)^4}{\sigma} \quad (3)$$

avec μ est la moyenne des coefficients AC , et σ son écart-type. La mesure de distorsion de structure v_2 est ainsi calculée par la moyenne des valeurs au dessous du $10^{\text{ème}}$ percentile.

3. Anisotropie d'orientation (v_3 et v_4). Les auteurs dans [14] montrent que la dégradation a un impact sur l'information directionnelle d'une scène. Par conséquent, l'anisotropie (qui dépend de l'information directionnelle d'une scène) est calculée en utilisant l'entropie de Rényi (qui est une généralisation de l'entropie de Shannon) sur les blocs DCT selon quatre orientations différentes $\theta = 0, 45, 90, 135$ en degrés. Les deux mesures v_3 et v_4 sont calculées comme suit : les coefficients DCT du $k^{\text{ème}}$ bloc autour de l'orientation θ sont notés par $P_\theta[k, j]$, avec j est l'indice du coefficient DCT. Chaque coefficient du bloc DCT est ensuite normalisé par :

$$\tilde{P}_\theta[k, j] = \frac{P_\theta[k, j]^2}{\sum_{j=1}^N P_\theta[k, j]^2} \quad (4)$$

avec N la taille du $k^{\text{ème}}$ bloc orienté et son entropie de Rényi R_θ^k est défini par :

$$R_\theta^k = \frac{1}{1 - \beta} \log_2 \left(\sum_{j=1}^N \tilde{P}_\theta[k, j]^\beta \right) \quad (5)$$

où $\beta > 1$. Enfin, les deux mesures basées sur l'anisotropie sont définies par :

$$v_3 = \text{var}(E(R_\theta^k)) \text{ et } v_4 = \max(E(R_\theta^k)), \forall k, \forall \theta \quad (6)$$

Dans cette étude, on fixera $\beta = 3$ (après expérimentation). Étant donné que la perception visuelle de l'image dépend de la résolution de l'image, la distance entre le plan de l'image et l'observateur, et l'acuité des observateurs, une approche multi-échelles est appliquée afin de calculer un score global :

$$\text{BLIINDS} = \prod_{i=1}^L v_1^{\alpha_1^i} v_2^{\alpha_2^i} v_3^{\alpha_3^i} v_4^{\alpha_4^i} \quad (7)$$

avec $\sum_{j=1}^4 \sum_{i=1}^L \alpha_j^i = 1$ et L représente le nombre de niveaux de décomposition utilisé. Les valeurs α_j^i ont été obtenues en calculant la corrélation de chacun des critères (v_i) avec les notes de qualité fournies par les observateurs humains [13].

2.2 Qualité du descripteur

La mesure de la qualité d'un descripteur est basée sur des mesures statistiques de points d'intérêt. Nous avons utilisé les points d'intérêt puisqu'ils décrivent de façon stable les régions de l'image où l'information est importante. Cette approche est généralement utilisée pour reconnaître des objets et dans les algorithmes de reconnaissance biométrique. Pour le calcul du vecteur descripteur au voisinage des points détectés, il existe de nombreuses méthodes tels que *Scale Invariant Feature Transform* (SIFT) [10], *Shape Contexts* [15], *Speed Up Robust Features* (SURF) [16]. Parmi ces algorithmes, l'algorithme SIFT proposé par Lowe [10] est retenu pour deux raisons principales. Premièrement, l'algorithme SIFT est efficace au changement d'échelle et à la rotation 2D. Deuxièmement, une étude comparative [17] de différents descripteurs montre que SIFT est le plus performant. L'algorithme SIFT a été également utilisé par Berretti *et al.* [18] dans le cas de reconnaissance faciale 3D.

L'algorithme SIFT, publié par Lowe en 1999 [10], permet de détecter et de décrire les caractéristiques d'une image. En utilisant SIFT, l'image I est caractérisée par l'ensemble $Y(I) = \{k_i = (x_i, y_i, \sigma_i, \theta_i, v_i) \mid i = 1 : N(I)\}$ avec $N(I)$ le nombre de points d'intérêt détectés dans I ; (x_i, y_i) la position du point d'intérêt i dans I ; (σ_i, θ_i) l'échelle et l'orientation du point d'intérêt i ; et v_i le vecteur (à 128 éléments) de descripteurs du point d'intérêt i .

À partir de ces caractéristiques et après expérimentations basées sur le coefficient de corrélation de Pear-

son, nous avons choisi d'utiliser quatre critères pour prédire la qualité du descripteur :

1. Le nombre de points d'intérêt détectés dans l'image I ;
2. Le coefficient DC de la matrice MAT , avec $N(I)$ lignes et 128 colonnes, contenant les vecteurs descripteurs des points d'intérêt détectés dans I ;
3. La moyenne et
4. l'écart-type du vecteur contenant l'échelle de chaque point d'intérêt détecté dans I .

Finalement, nous disposons de cinq critères (un dédié à la qualité de l'image et quatre sur la qualité du descripteur) pour établir le niveau de qualité de données biométriques. Au lieu de faire un cumul des valeurs ainsi obtenues, nous proposons d'utiliser un algorithme de classification de la qualité à 10 classes où

- La classe 1 correspond à une image de référence (c'est à dire non altérée) ;
- Les classes 2 à 10 correspondent à 3 types d'altérations et 3 niveaux pour chaque type d'altération, respectivement. Une description détaillée des altérations introduites est donnée à la Section 3.

2.3 Classification par SVM

Les machines à vecteurs de support ou Séparateurs à Vastes Marges sont des méthodes de classification par apprentissage supervisé développées par Vapnik [19]. Elle est connue sous le terme anglais par *Support Vectors Machine* (SVM). Le but des SVM est de classer un objet x à l'aide d'une marge maximale associée à des vecteurs de supports et d'une fonction noyau. Cette méthode est devenue populaire du fait de ces performances à traiter des données de grande dimension. La fonction noyau permet d'opérer un changement de repère dans un espace de plus grande dimension afin de retrouver un problème de séparation linéaire, lorsque les données ne sont pas linéairement séparables. Soit une base d'apprentissage $S_{\text{apprentissage}} = \{(x_1, y_1), \dots, (x_m, y_m)\}$ composée de m couples (vecteur d'attributs, classe) avec $x_i \in \mathbb{R}^n$ et $y_i \in \{-1, 1\}$. L'algorithme SVM projette les valeurs x_i dans un espace de travail \mathcal{H} ($\phi : \mathbb{R}^n \rightarrow \mathcal{H}$). L'hyperplan optimal de séparation des deux classes dans l'espace \mathcal{H} est ensuite recherché. Cet hyperplan (w, b) matérialise la frontière de séparation entre les deux classes. La classe y d'un nouvel exemple x est définie par :

$$y = \langle w, \Phi(\mathbf{x}) \rangle + b = \sum_{i=1}^{\ell} \alpha_i^* y_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (8)$$

avec $\alpha_i^* \in R$ et $K(\cdot, \cdot)$ est la fonction noyau. Dans l'algorithme SVM, l'hyperplan est optimal s'il maximise

la distance qui le sépare des exemples dont il est le plus proche. Cette distance est appelée marge du classifieur. Les α_i^* qui maximisent le critère d’optimalité sont obtenus en résolvant :

$$\max_{\alpha_i} \sum_{i=1}^{\ell} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} \alpha_i \alpha_j y_i K(\mathbf{x}_i, \mathbf{x}_j y_j) \quad (9)$$

sous les contraintes, $0 \leq \alpha_i \leq C$ et $\sum_{i=1}^{\ell} \alpha_i y_i = 0$, avec C est le coefficient de pénalisation. L’algorithme SVM de base a été développé pour les problèmes de classification à deux classes. Cependant, plusieurs approches peuvent être utilisées pour l’étendre aux problèmes multi-classes. Dans nos travaux, nous avons utilisé l’approche *un contre un* avec le critère de vote majoritaire pour la sélection de la classe finale. Nous avons utilisé un script python (*easy.py*) fourni par la librairie libsvm [20]. Une recherche par grid search est effectuée pour la recherche des deux paramètres optimaux C et γ , et le noyau utilisé est le noyau RBF défini par :

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (10)$$

3 Protocole expérimental

Quatre bases de visages *FACES* [21], *ENSIB* [22], *FERET* [23], *AR* [24], une d’empreintes digitales *FVC2002 DB₂* [25] et une des veines de la main collectée par Télécom & Management SudParis [26] ont été utilisées. Pour chacune des bases de référence utilisées, nous avons simulé plusieurs artefacts d’acquisition (mouvement, bruit gaussien et distance d’acquisition), et appliqué trois niveaux de dégradation pour chaque type d’altération : altération par 1) mouvement (flou), 2) bruit gaussien et 3) distance d’acquisition (redimensionnement). La Figure 2 illustre un exemple de ces altérations sur une image de la base de données *FACES94*, pour les trois niveaux de dégradation appliqués à chaque type d’altération.

Le système de vérification retenu est basé sur la détection des points d’intérêt et le descripteur SIFT. La vérification entre deux images I_1 et I_2 correspond au calcul du nombre d’associations entre les deux ensembles $Y(I_1)$ et $Y(I_2)$. Une association est définie par une double mise en correspondance entre deux points d’intérêt. La méthode de mise en correspondance utilisée est celle présentée par Ladoux *et al.* [26] (version modifiée de la méthode proposée par Lowe [10]).

Selon Grother et Tabassi [27], les méthodes de qualité doivent prédire la performance des systèmes biométriques. Cela signifie qu’une méthode de qualité prend en entrée une donnée biométrique, et prédit sa

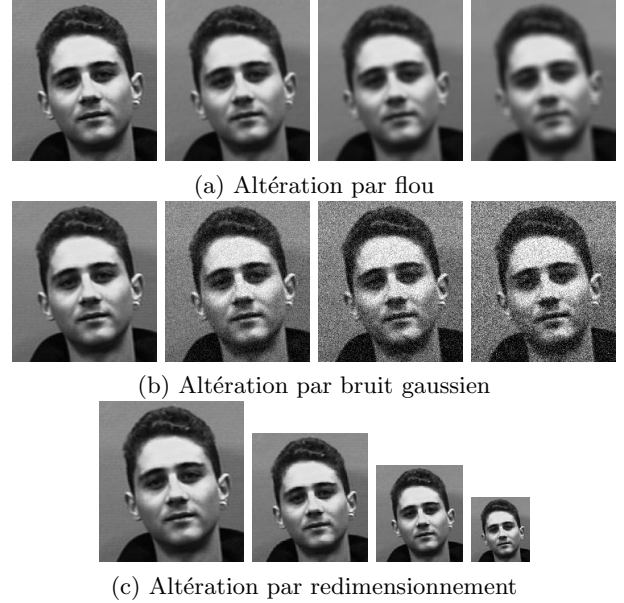


Figure 2 – Exemple d’altérations sur une image de la base de données *FACES94*. Du gauche à droite, image de référence ensuite images altérées niveau 1, 2 et 3, respectivement

catégorie de qualité lié au taux d’erreur associée à cette donnée. Afin de quantifier la performance de la méthode proposée, nous procédons comme suit :

- Apprentissage des SVM multi-classes : pour les bases de visages, nous avons généré quatre SVM multi-classes (*i.e.*, un SVM multi-classes par base), et un SVM multi-classes contenant des exemples de toutes les bases (SVM_{tout}). Pour les bases d’empreintes digitales et de veines de la main, nous avons généré deux autres SVM multi-classes, respectivement. Pour apprendre et tester les différents SVM multi-classes, nous avons divisé chaque base d’images en deux ensembles distincts $S_{apprentissage}$ et S_{test} d’une manière équilibrée (*i.e.*, le même nombre d’exemples par classe existe dans les deux ensembles). Le choix du noyau utilisé et les paramètres requis sont présentés dans la Section 2.3 ;
- Définition des catégories de qualité : la méthode SVM multi-classes proposée prédit une classe de qualité pour une image en entrée. Afin de quantifier la performance de cette méthode, nous devons tout d’abord définir les catégories de qualité pour le système de vérification utilisé. Selon la nature de ce système, certaines altérations peuvent avoir un impact sur sa performance globale plus que d’autres. Par la suite, l’EER est utilisé pour illustrer la performance globale d’un système biométrique ;
- Corrélation des valeurs de l’EER avec les catégo-

ries de qualité : afin de quantifier l’efficacité de la méthode proposée pour prédire les performances du système testé, nous calculons l’EER de chaque catégorie de qualité. L’intérêt de la méthode proposée est ainsi quantifié par son efficacité pour prédire les performances du système testé. En d’autres termes, plus les données biométriques sont dégradées, plus la performance globale du système est dégradée (cela se traduit par une augmentation des valeurs de l’EER).

4 Résultats expérimentaux

Les performances des sept SVM multi-classes générés (cinq pour les bases de visages et deux pour les bases d’empreintes digitales et de veines de la main) sont donnés dans le Tableau 1. Nous avons mis le symbole « \times » pour les bases d’empreintes digitales et de veines de la main, car nous avons généré un seul SVM multi-classes par base. Le Tableau 1 montre l’intérêt de la méthode proposée pour détecter les trois types d’altérations réelles (flou, bruit gaussien et redimensionnement) des données, avec des taux de bonne classification satisfaisants (de 82.29% jusqu’à 97.73% sur la base d’apprentissage, et de 81.16% jusqu’à 91.1% sur la base de test).

Afin de définir les catégories de qualité, nous avons testé la robustesse du système testé contre les altérations introduites dans la Section 3. Pour ce faire, nous avons calculé l’EER de chaque base de référence, puis les valeurs d’EER en ajoutant des images dégradées. Les valeurs d’EER sont calculées en utilisant la première image de référence pour l’enrôlement, et les autres pour le test. Pour chaque base utilisée, nous avons obtenu des valeurs d’EER croissantes. Cela montre que toutes les altérations introduites ont un impact sur la performance du système biométrique étudié.

Par conséquent, nous définissons dans le Tableau 2 les catégories de qualité retenues pour le système biométrique utilisé. La Figure 3 présente les valeurs d’EER de chaque catégorie de qualité. La méthode proposée a montré son efficacité à prédire les performances du système testé. En d’autres termes, plus les images sont dégradées, plus la performance globale du système est dégradée (cela se traduit par une augmentation de l’EER). Pour la base de veines de la main, nous avons obtenu une légère augmentation des valeurs d’EER (0% : catégorie bonne jusqu’à 0.05% : catégorie très mauvaise). Ceci peut être expliqué par la faible taille de la base utilisée (24 personnes et 30 images par personne), et par la robustesse de la méthode de vérification SIFT face aux altérations.

	SVM_{chaque}		SVM_{tout}	
	$S_{apprentissage}$	S_{test}	$S_{apprentissage}$	S_{test}
FACES94	91,01	86,69	85,68	85,28
ENSIB	97,73	89,82	94,92	91,1
FERET	82,33	81,2	82,29	81,16
AR	90,08	89,08	90,7	88,92
FVC2002 DB_2	\times	\times	91,7	83,68
Veines	\times	\times	95,25	90,2

Tableau 1 – Précision (en %) des modèles SVM multi-classes sur les deux ensembles d’apprentissage ($S_{apprentissage}$) et de test (S_{test}).

Label prédit par le SVM multi-classes	Description
1	Bonne
2, 5 et 8	Moyenne
3, 6 et 9	Mauvaise
4, 7 et 10	Très mauvaise

Tableau 2 – Catégories de qualité.

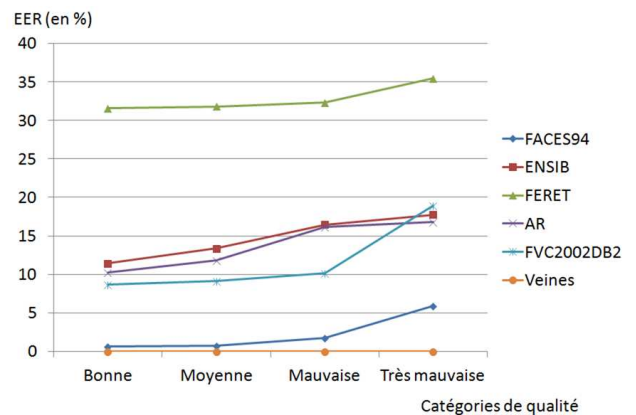


Figure 3 – Les valeurs d’EER de chaque catégorie de qualité sur les six bases.

5 Conclusion et perspectives

Nous avons présenté dans cet article, une méthode pour prédire la qualité de données biométriques morphologiques (représentées par une image). La méthode proposée utilise deux types d’informations complémentaires : 1) la qualité de l’image, et 2) la qualité des paramètres extraits en utilisant le descripteur SIFT. L’approche proposée est plurimodale (visage, empreinte digitale et veines de la main), et indépendante du système de vérification utilisé. Nous avons montré son intérêt pour détecter trois types d’altérations réelles (flou, bruit gaussien et redimensionnement) des données, qui ont un impact majeur sur la performance globale des systèmes biométriques.

Pour les perspectives, nous comptons ajouter un sixième critère pour détecter l’altération par luminosité, qui a un impact significatif sur la plupart des systèmes de reconnaissance faciale existants. Outre la qualité de données morphologiques, nous comptons travailler sur la qualité de données comportementales

(*ex.*, dynamique de frappe au clavier). Cette information est utile puisque l'acquisition de données comportementales est sensible à divers types d'artefact liés au comportement des usagers (individu coopératif) et au lieu d'acquisition (environnement contrôlé).

Références

- [1] L. Shen, A. C. Kot, et W. M. Koo. Quality measures of fingerprint images. Dans *Proceedings of the 3rd International Conference on Audio- and Video-Based Biometric Person Authentication (AVBPA)*, pages 266–271, 2001.
- [2] Y. Chen, S. C. Dass, et A. K. Jain. Fingerprint quality indices for predicting authentication performance. Dans *5th International Conference Audio- and Video-Based Biometric Person Authentication (AVBPA)*, volume 3546, pages 160–170, 2005.
- [3] S. Lee, C. Lee, et J. Kim. Model-based quality estimation of fingerprint images. Dans *IAPR/IEEE International Conference on Biometrics (ICB'06)*, pages 229–235, 2006.
- [4] E. Krichen, S. Garcia Salicetti, et B. Dorizzi. A new probabilistic iris quality measure for comprehensive noise detection. Dans *IEEE Third International Conference on Biometrics : Theory, Applications and Systems (BTAS)*, pages 1–6, 2007.
- [5] X.F. Gao, S.Z. Li, R. Liu, et P.R. Zhang. Standardization of face image sample quality. Dans *International Conference on Biometrics (ICB'07)*, pages 242–251, 2007.
- [6] E. Tabassi et C.L. Wilson. A novel approach to fingerprint image quality. Dans *International Conference on Image Processing (ICIP)*, pages 37–40, 2005.
- [7] G. Zhang et Y. Wang. Asymmetry-based quality assessment of face images. Dans *Proceedings of the 5th International Symposium on Advances in Visual Computing (ISVC)*, volume 5876, pages 499–508, 2009.
- [8] J. Sang, Z. Lei, et S. Z. Li. Face image quality evaluation for ISO/IEC standards 19794-5 and 29794-5. Dans *Proceedings of the Third International Conference on Advances in Biometrics (ICB)*, pages 229–238, 2009.
- [9] Q. He, Z.A. Sun, T.N. Tan, et Y. Zou. A hierarchical model for the evaluation of biometric sample quality. Dans *International Conference on Pattern Recognition (ICPR)*, pages 1–4, 2008.
- [10] D. G. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision (IJCV)*, 60 :91 – 110, 2004.
- [11] M. Jung, D. Lger, et M. Gazelet. Univariant assessment of the quality of images. *Journal of Electronic Imaging*, 11(3) :354–364, 2002.
- [12] C. Charrier, G. Lebrun, et O. Lezoray. A machine learning-based color image quality metric. Dans *Third European Conference on Color Graphics, Imaging, and Vision*, pages 251–256, 2006.
- [13] M. Saad, A. C. Bovik, et C. Charrier. A DCT statistics-based blind image quality index. *IEEE Signal Processing Letters*, 17(6) :583–586, 2010.
- [14] S. Gabarda et G. Cristbal. Blind image quality assessment through anisotropy. *Journal of Optical Society of America*, pages B42–B51, 2007.
- [15] S. Belongie, J. Malik, et J. Puzicha. Matching shapes. Dans *International Conference on Computer Vision*, pages 454 – 461, 2001.
- [16] H. Bay, A. Ess, T. Tuytelaars, et L. Van Gool. Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 110 :346 – 359, 2008.
- [17] K. Mikolajczyk et C. Schmid. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 27 :1615–1630, 2005.
- [18] S. Berretti, A. D. Bimbo, P. Pala, B. B. Amor, et M. Daoudi. A set of selected sift features for 3D facial expression recognition. Dans *Proceedings of the 20th International Conference on Pattern Recognition (ICPR)*, pages 4125–4128, 2010.
- [19] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer-Verlag, 1995.
- [20] Chih-Chung Chang et Chih-Jen Lin. *LIBSVM : a library for support vector machines*, 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [21] University of Essex. Faces94 database, face recognition data, 1994.
- [22] B. Hemery, C. Rosenberger, et H. Laurent. The ENSIB database : a benchmark for face recognition. Dans *International Symposium on Signal Processing and its Applications (ISSPA), special session "Performance Evaluation and Benchmarking of Image and Video Processing"*, 2007.
- [23] P.J. Phillips, H. Wechsler, J. Huang, et P. Rauss. The FERET database and evaluation procedure for face recognition algorithms. *Journal of Image and Vision Computing*, 16 :295–306, 1998.
- [24] A.M. Martinez et R. Benavente. The AR face database. *CVC Tech. Report*, 1998.
- [25] D. Maio, D. Maltoni, R. Cappelli, J. L. Wayman, et A. K. Jain. Fvc2002 : Second fingerprint verification competition. Dans *International Conference on Pattern Recognition (ICPR'02)*, volume 3, pages 811 – 814, 2002.
- [26] P.-O. Ladoux, C. Rosenberger, et B. Dorizzi. Palm vein verification system based on sift matching. Dans *the 3rd IAPR/IEEE International Conference on Biometrics (ICB'09)*, pages 1290–1298, 2009.
- [27] P. Grother et E. Tabassi. Performance of biometric quality measures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29 :531–543, 2007.