

# Segmentation d'images des yeux par champs de Markov triplets: Applications à la biométrie

DALILA BENBOUDJEMA<sup>1</sup>, NADIA OTHMAN<sup>2</sup>, BERNADETTE DORIZZI<sup>2</sup>, WOJCIECH PIECZYNSKI<sup>1</sup>

<sup>1</sup> Département CITI, <sup>2</sup> Département EPH,  
Institut Mines-Télécom/Télécom SudParis/CNRS UMR 5157, 9 rue Charles Fourier 91011 Evry, France

<sup>1</sup>dbenboudjema@gmail.com, wojciech.pieczynski@telecom-sudparis.eu,  
<sup>2</sup>nadia.othman@telecom-sudparis.eu, bernadette.dorizzi@telecom-sudparis.eu

**Résumé** - Nous proposons d'utiliser la technique des champs de Markov triplet (CMT) pour effectuer une segmentation non supervisée de la région périoculaire d'images considérées comme difficiles dans le cadre de la reconnaissance d'iris. Les résultats obtenus confirment l'intérêt de l'utilisation des CMTs par rapport aux champs de Markov caché (CMCs) et aux traditionnelles approches basées sur les gradients pour la segmentation d'iris. Nous avons en effet montré que la précision des cercles de normalisation est nettement améliorée en utilisant le modèle CMT malgré la qualité dégradée des images. Ces résultats sont prometteurs pour une intégration de ces approches dans les systèmes de vérification de l'iris.

**Abstract** - We present a novel implementation of Triplet Markov Fields (TMF) for the unsupervised region segmentation of challenging eye images, representative of the iris recognition context. Results confirm the interest of such models over the classical Hidden Markov Field (HMF) and traditional gradient-based approaches for iris and periocular detection. We show that the precision of the resulting normalization circles is largely improved through the use of such TMF model as well as the quality of the image segmentation, despite of various degradations. These results are promising for further integration of TMF approaches in iris verification systems.

## 1 Introduction

Parmi les diverses modalités biométriques physiologiques qui peuvent permettre l'identification des personnes, la texture de l'iris est remarquable de par sa faculté d'obtenir des systèmes qui présentent un très faible taux d'erreur [1, 2]. Cependant, ce niveau élevé de performance ne peut être obtenu qu'au prix de lourdes contraintes imposées à la personne lors de l'acquisition. Les perspectives sont de relâcher ces contraintes afin de rendre les systèmes plus conviviaux, mais la qualité d'image qui en résulte est alors fortement dégradée en raison du flou et de variations d'éclairage. Il a été montré que l'utilisation d'informations périoculaires (forme de la paupière, du coin interne de l'œil, cils...) en complément de la texture classique de l'iris apporte des améliorations importantes dans ce contexte dégradé [3]. La colonne de gauche de la Figure 1 montre quelques exemples d'images oculaires difficiles acquises dans le proche infrarouge.

La décision d'authentification biométrique est fondée sur une comparaison entre deux iris. À cette fin, la texture doit être transformée dans un système de coordonnées sans dimension pour gérer les variabilités comme la dilatation de la pupille. Dans le modèle « rubbersheet » introduit par Daugman dans [1], les frontières de l'iris sont modélisées par deux cercles non concentriques et la texture est représentée par un rectangle qui résulte de la déformation de la zone circulaire entre les 2 cercles. Le but de la segmentation dans un système iris est donc double. Les contours paramétriques de la région d'iris servent à dérouler la texture de l'iris pour produire l'image normalisée.

Enfin, l'identification des pixels appartenant à l'iris dans l'image de l'œil permet de générer un masque de segmentation, qui sera utilisé pour enlever des artefacts de l'image normalisée à l'étape de mise en correspondance.

La plupart des approches proposées dans la littérature pour la segmentation d'iris recherchent des contours à partir d'une image de gradients et utilisent des techniques de contours actifs [4, 5]. Le travail de Pundlik et al. [6] suit une autre voie : ces auteurs proposent de s'appuyer sur une segmentation non supervisée des différentes régions de l'œil (pupille, iris et fond) en utilisant les valeurs d'intensité de pixels pour détecter ensuite les contours de l'iris. Dans ce but, ils utilisent un champ de Markov caché (CMC) et un algorithme de minimisation d'énergie basé sur les « graph cut ».

Dans cet article, nous proposons de suivre la même tendance et d'explorer des approches markoviennes plus récentes, à savoir celles fondées sur les champs de Markov Triplets (CMTs). Introduits dans [7], les CMTs étendent les CMCs classiques par l'addition d'un champ aléatoire auxiliaire qui gère les non stationnarités et se révèlent être plus efficaces que ceux-ci dans différentes situations complexes [8, 9, 10, 11]. Nous allons mettre en œuvre des approches utilisant des CMTs pour la segmentation non supervisée (les paramètres sont estimés par une méthode de type « Iterative Conditional Estimation », ICE) des yeux et montrer sur certaines images difficiles le bon comportement des CMTs par rapport aux CMCs. En effet, nous allons montrer que la précision des cercles de normalisation peut être

fortement améliorée par l'utilisation de la segmentation CMT. Cette propriété sera très utile dans la construction d'un système de reconnaissance de l'iris complet. Cette approche permet aussi une très bonne qualité de la détection des cils et des coins des yeux, d'où son fort potentiel pour l'analyse périoculaire.

## 2 Modélisation statistique

Soit  $S$  un ensemble de pixels de cardinal  $N$ , et  $X = (X_s)_{s \in S}$ ,  $Y = (Y_s)_{s \in S}$  deux champs aléatoires,  $X$  étant caché et  $Y$  étant observé. Chaque variable aléatoire  $X_s$  est à valeurs dans l'ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_k\}$  et chaque variable aléatoire  $Y_s$  est à valeurs dans  $R$ . En segmentation d'images, l'objectif est de retrouver  $X$  à partir de  $Y$ , qui peut être interprété comme une version «bruitée» de  $X$ . A cet effet, nous devons définir la loi de  $(X, Y)$ , qui est classiquement obtenue à partir de la loi de  $X$  et de celle de  $Y$  conditionnelle à  $X$ . Dans le cas de la modélisation par champs de Markov cachés (CMC) classiques,  $X$  est supposé markovien. Sa loi est alors donnée par:

$$p(x) = \gamma \exp\left[-\sum_{c \in C} \varphi_c(x_c)\right], \quad (2.1)$$

où  $C$  est l'ensemble de cliques, une clique étant soit un singleton, soit un ensemble de pixels mutuellement voisins (au sens du système de voisinages définissant la markovianité). La loi conditionnelle  $p(y|x)$  vérifie les deux hypothèses suivantes:

- H1:  $p(y_s|x) = p(y_s|x_s)$  pour chaque  $s \in S$ ;
- H2:  $p(y|x) = \prod_{s \in S} p(y_s|x)$ .

La loi conditionnelle  $p(y|x)$  est alors  $p(y|x) = \prod_{s \in S} p(y_s|x_s) = \exp \sum_{s \in S} \log p(y_s|x_s)$ , et la loi du couple  $(X, Y)$  s'écrit donc

$$p(x, y) = p(x)p(y|x) = \gamma \exp\left[-\sum_{c \in C} \varphi_c(x_c) + \sum_{s \in S} \log p(y_s|x_s)\right] \quad (2.2)$$

Dans un tel modèle, la loi de  $X$  a posteriori  $p(x|y)$  est markovienne, ce qui permet la mise en place de différentes stratégies bayésiennes de son estimation. Ces modèles ont été généralisés aux modèles de Markov «couples» [15], dont la loi s'écrit

$$p(x, y) = \gamma \exp\left[-\sum_{c \in C} \varphi_c(x_c, y_c)\right] \quad (2.3)$$

Dans un champ de Markov couple la loi  $p(x|y)$  est markovienne, ce qui permet les mêmes traitements que dans les CMC; cependant,  $X$  n'est plus nécessairement de Markov et on obtient donc une famille de modèles plus générale que celle des CMCs. Les champs de Markov couples ont par la suite été généralisés aux champs de Markov triplets (CMTs). Dans ces derniers on introduit un troisième champs

aléatoire  $U = (U_s)_{s \in S}$ , chaque variable aléatoire  $U_s$  étant à valeurs dans l'ensemble fini  $\Lambda = \{\lambda_1, \dots, \lambda_m\}$ , et on considère la markovianité du triplet  $T = (X, U, Y)$  [7, 8, 16]. Il est alors possible d'estimer le couple  $V = (X, U)$ ; en effet, le champ  $V$  est discret à valeurs dans un ensemble fini et donc  $T = (V, Y)$  est un champ de Markov couple. En particulier, le champ supplémentaire  $U$  peut modéliser les différentes textures présentes dans l'image de classes  $X$  [8], ou différentes stationnarités du bruit, comme étudié dans [14], même si le modèle utilisé est celui des chaînes de Markov triplets.

Dans le présent travail nous avons utilisé les CMT définis par rapport au système des quatre plus proches voisins, avec le champ  $U$  prenant deux valeurs possibles:  $\Lambda = \{a, b\}$ . Nous reprenons le modèle proposé dans [8], dont la loi s'écrit (les  $p(y_s|x_s)$  sont supposées gaussiennes):

$$p(x, u, y) = \gamma \exp\left[-W(x, u) + \sum_{s \in S} \text{Log}(p(y_s|x_s))\right], \quad (2.4)$$

où

$$\begin{aligned} W(x, u) = & \sum_{(s,t) \in C_H} \alpha_H^1 (1 - 2\delta(x_s, x_t)) - (\alpha_{aH}^2 \delta^*(u_s, u_t, a) \\ & + \alpha_{bH}^2 \delta^*(u_s, u_t, b))(1 - \delta(x_s, x_t)) \\ & + \sum_{(s,t) \in C_V} \alpha_V^1 (1 - 2\delta(x_s, x_t)) - (\alpha_{aV}^2 \delta^*(u_s, u_t, a) \\ & + \alpha_{bV}^2 \delta^*(u_s, u_t, b))(1 - \delta(x_s, x_t)), \end{aligned} \quad (2.5)$$

avec  $\delta^*(u_s, u_t, a) = 1$  pour  $u_s = u_t = a$ , et  $\delta^*(u_s, u_t, a) = 0$  sinon,  $\delta(u_s, u_t, b) = 1$  pour  $u_s = u_t = b$ , et  $\delta^*(u_s, u_t, b) = 0$  sinon. Cette loi est définie de manière à ce que, conditionnellement à  $U$ , les paramètres de la loi du champ des classes  $X$  dépendent des textures « $a$ » et « $b$ ».

L'estimation du champ caché  $V = (X, U)$  se fait alors classiquement par la méthode bayésienne «maximum des marginales a posteriori» (MPM): on simule, par l'échantillonneur de Gibbs,  $m$  réalisations  $v_1 = (x_1, u_1)$ , ...,  $v_m = (x_m, u_m)$  de  $V = (X, U)$  selon sa loi a posteriori  $p(x, u|y)$ , que l'on utilise pour estimer les lois marginales a posteriori  $p(x_s, u_s|y)$ , ces dernières donnant les lois  $p(x_s|y)$  dont la maximisation mène à la segmentation.

Pour  $k$  classes le vecteur  $\theta$  des paramètres du modèle considéré est composé des six paramètres  $\alpha = (\alpha_H^1, \alpha_{aH}^2, \alpha_{bH}^2, \alpha_V^1, \alpha_{aV}^2, \alpha_{bV}^2)$  figurant dans (2.5),  $k$  moyennes, et  $k$  variances des  $k$  gaussiennes  $p(y_s|x_s = \omega_1), \dots, p(y_s|x_s = \omega_k)$ . Tous ces paramètres sont estimés par méthode «iterative conditional estimation» (ICE), dont l'allure générale est la suivante (les détails pourront être consultés dans [16]):

- (1) Initialiser les paramètres en déterminant  $\theta^0$  ;
- (2) à chaque itération  $q$  :
  - simuler, en utilisant les paramètres courants  $\theta^q$ , une réalisation  $v^q = (x^q, u^q)$  de  $V = (X, U)$  selon sa loi a posteriori  $p(x, u|y)$  ;
  - utiliser  $v^q$  pour estimer  $\alpha$ , ce qui donne  $\alpha^{q+1}$  ;
  - utiliser  $x^q$  pour estimer les moyennes et les variances des gaussiennes, ce qui aboutit au vecteur suivant  $\theta^{q+1}$ .
- (3) stopper les itérations selon un critère adapté à l'application considérée.

Dans notre approche nous considérons quatre classes « iris », « cils », « pupille », et « fond », nous avons donc quatre gaussiennes et le nombre total des paramètres est de quatorze.

### 3 Résultats expérimentaux

#### 3.1 Comparaison entre les approches CMT et CMC pour la segmentation des yeux

La colonne de gauche, du milieu et de droite de la figure 1 correspond respectivement à l'image originale d'un œil, sa segmentation en 4 classes par un CMC, puis par un CMT, sans aucun prétraitement. Les images originales souffrent de mauvaise qualité et sont, de ce fait, difficiles à traiter. Par exemple, l'image originale de la 1<sup>ère</sup> ligne de la figure 1 est peu contrastée. Dans ce cas, le CMC n'arrive pas à distinguer la pupille de l'iris, contrairement au CMT qui les segmente bien en 2 classes distinctes. Pour l'image de la 2<sup>ème</sup> ligne qui est très floue, le CMT segmente correctement l'iris et la pupille. De plus, il détecte très bien les cils contrairement au CMC. L'image originale de la 3<sup>ème</sup> ligne présente de fortes occlusions, de l'ombre et aussi une variation d'illumination. Pour ce type d'image, la segmentation CMT est nettement meilleure que celle du CMC. L'iris est bien séparé du blanc d'œil, et les cils sont bien détectés ce qui est très utile pour générer de bons masques pour comparer la texture de l'iris lors de l'étape de mise en correspondance pour l'identification de personnes.



Figure 1: Segmentation des yeux d'images non-ideales (gauche) par CMC (milieu) et par CMT (droite).

#### 3.2 Précision des cercles de normalisation

Dans ce travail, nous nous limitons à des frontières circulaires et les paramètres des cercles de normalisation (centre et rayon de la pupille et de l'iris) sont fournis par le module de segmentation du système de référence OSIRIS\_V4 qui utilise un algorithme de Viterbi et une méthode des moindres carrés sur une image de gradients pour déterminer les paramètres des cercles [12]. Nous avons évalué la précision des cercles de normalisation sur un sous-ensemble d'images fortement dégradées (236 images) sélectionné manuellement à partir de la base ICE2005 [13]. Une segmentation manuelle a été utilisée comme vérité terrain pour comparer les paramètres des cercles donnés par OSIRIS\_V4 sur les images originales et sur les images segmentées en 4 classes par le CMT.

Pour chaque méthode, les erreurs (pour pupille et iris) sont calculées comme la distance euclidienne entre le centre obtenu et le centre déterminé par la réalité terrain et sont normalisées par rapport au rayon. La figure 2 montre les histogrammes cumulés des erreurs en pixels sur les centres détectés par OSIRIS\_V4 sur les images originales et sur les images segmentées par le CMT pour la pupille et l'iris. A partir de ces résultats, on peut conclure qu'en utilisant la segmentation CMT, 91% et 92% des images ont respectivement une erreur normalisée sur le centre de la pupille et de l'iris de moins de 0,1 (à comparer à 76% et 90% sans utiliser la segmentation CMT). On remarque sur cette figure 2 une amélioration globale de la localisation du centre de pupille et l'iris grâce à la segmentation CMT, qui est plus visible pour le centre du cercle de la pupille que pour celui de l'iris.

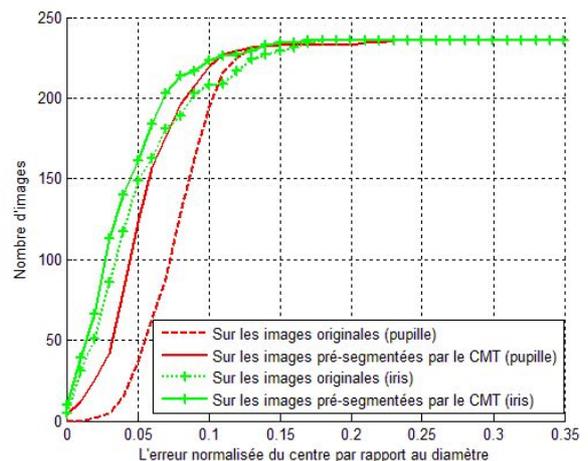


Figure 2: Histogrammes cumulés en pixels des centres des cercles de la pupille et de l'iris détectés par OSIRIS\_V4 sur les images originales et pré-segmentées par le CMT.

La Figure 3 montre l'historgramme des erreurs en pixels des centres des pupilles avec ou sans segmentation CMT. On constate que la distribution des erreurs du centre de la pupille se déplace vers zéro avec la segmentation CMT, ce qui indique une plus grande précision dans les cercles de normalisation. En outre, nous notons une amélioration d'environ 50% pour la

valeur des 2 pics des 2 distributions (de 0,055 contre 0,095).

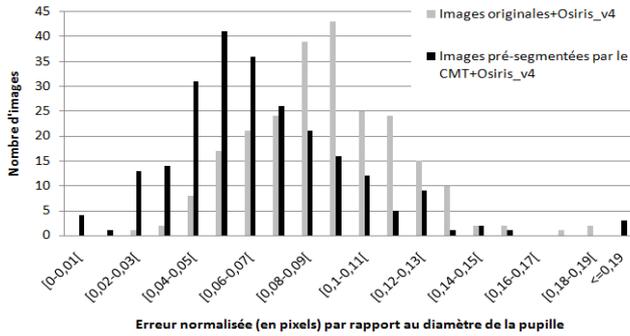


Figure 3: Histogrammes des erreurs normalisées du centre de la pupille pour les cercles détectés par OSIRIS\_V4 sur les images originales et segmentées par CMT.

## 4 Conclusion

Dans ce travail, nous avons proposé une implémentation de Champ Markov Triplet pour la segmentation des yeux dans le cas d'images considérées comme difficiles pour la reconnaissance de personne à partir de l'iris. Nous avons montré que le modèle CMT segmente les images plus efficacement que les traditionnels Champs de Markov Cachés. Malgré le flou, les fortes occlusions et le faible contraste des images, le CMT utilisé parvient, contrairement au CMC, à segmenter finement les cils, les paupières et le coin interne de l'œil. Par contre, cette implémentation reste sensible aux problèmes d'illumination. Une de nos perspectives consisterait à étendre le CMT en intégrant explicitement des modèles d'ombre, comme cela est proposé dans [14] dans le cas des chaînes de Markov cachées. Nous avons également montré la bonne qualité de détection des cercles de normalisation en utilisant le CMT, ce qui permettra d'améliorer les taux de reconnaissance d'iris. De plus la segmentation CMT peut être utilisée pour l'analyse périoculaire.

Notons que les CMT utilisés dans ce travail sont très simples et l'augmentation du nombre d'états possibles du troisième champ, ou l'utilisation des systèmes de voisinages plus riches, est de nature à améliorer les résultats obtenus.

## 5 Bibliographie

- [1] J. G. Daugman, « High confidence visual recognition of persons by a test of statistical independence », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, n° 11, p. 1148-1161, 1993.
- [2] K. W. Bowyer, K. Hollingsworth, and P. J. Flynn, « Image understanding for iris biometrics: A survey », *Computer Vision and Image Understanding*, vol. 110, n° 2, p. 281-307, 2008.
- [3] D. L. Woodard, S. Pundlik, P. Miller, R. Jillela, and A. Ross, « On the fusion of periocular and iris

biometrics in non-ideal imagery », in *20th International Conference on Pattern Recognition*, p. 201-204, 2010.

- [4] J. Daugman, « New methods in iris recognition », *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 37, n° 5, p. 1167-1175, 2007.
- [5] A. Ross and S. Shah, « Segmenting non-ideal irises using geodesic active contours », in *Proceedings of Biometrics Symposium*, p. 1-6, 2006.
- [6] S. J. Pundlik, D. L. Woodard, and S. T. Birchfield, « Non-ideal iris segmentation using graph cuts », in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, p. 1-6, 2008.
- [7] W. Pieczynski, D. Benboudjema, and P. Lanchantin, « Statistical image segmentation using triplet Markov fields », in *SPIE's International Symposium on Remote Sensing*, p. 22-27, 2002.
- [8] D. Benboudjema and W. Pieczynski, « Unsupervised statistical segmentation of non-stationary images using triplet Markov fields », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, n° 8, p. 1367-1378, 2007.
- [9] J. Blanchet and F. Forbes, « Triplet Markov fields for the classification of complex structure data », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, n° 6, p. 1055-1067, 2008.
- [10] Y. Wu, M. Li, P. Zhang, H. Zong, P. Xiao, and C. Liu, « Unsupervised multi-class segmentation of SAR images using triplet Markov fields models based on edge penalty », *Pattern Recognition Letters*, vol. 32, n° 11, p. 1532-1540, 2011.
- [11] P. Zhang, M. Li, Y. Wu, L. Gan, M. Liu, F. Wang, and G. Liu, « Unsupervised multi-class segmentation of SAR images using fuzzy triplet Markov fields model », *Pattern Recognition Letters*, vol. 45, p. 4018-4033, 2012.
- [12] G. Sutra, S. Garcia-Salicetti, and B. Dorizzi, « The Viterbi algorithm at different resolutions for enhanced iris segmentation », *5th IAPR International Conference on Biometrics*, p. 310-316, 2012.
- [13] « Iris Challenge Evaluation 2005 », <http://www.nist.gov/itl/iad/ig/iris.cfm>.
- [14] M. E. Y. Boudaren, E. Monfrini, and W. Pieczynski, « Unsupervised segmentation of random discrete data hidden with switching noise distributions », *IEEE Signal Processing Letters*, vol. 19, n° 10, p. 619-622, 2012.
- [15] W. Pieczynski and A.-N. Tebbache, « Pairwise Markov random fields and segmentation of textured images », *Machine Graphics & Vision*, vol. 9, n°3, p. 705-718, 2000.
- [16] D. Benboudjema and W. Pieczynski, « Unsupervised image segmentation using triplet Markov fields », *Computer Vision and Image Understanding*, vol. 99, n°3, p. 476-498, 2005.

