

Classification d'images couleur texturées

A. Moussa*, M. Maouene*, I. Qazi**, O. Alata**, J. C. Burie***

A.Sbihi*

* Laboratoire LTI, ENSA, BP 1818, Université Abdelmalek Essaadi, Tanger, Maroc.

** Laboratoire XLIM-SIC, UMR CNRS 6172, Université de Poitiers, Bât. SP2MI, B.P. 30179, 86960, Futuroscope Cedex, France.

*** Laboratoire L3I, EA 2118, Université de La Rochelle, av. M. Crépeau, 17402, La Rochelle Cedex 1, France.

amoussa@ensat.ac.ma

.....
RÉSUMÉ. Ce papier présente une nouvelle méthode de classification des pixels d'une image couleur texturée en utilisant les erreurs de prédiction issues de modèles de prédiction linéaire dans différents espaces couleurs. Cette méthode consiste à calculer pour chaque pixel de l'image, soumise à l'analyse, une probabilité d'appartenance à une texture présente dans l'image. Cette probabilité utilise le concept de potentiel d'interaction, entre pixels, dans le voisinage immédiat du pixel candidat. La méthode proposée a été testée sur des images couleur texturées réelles en utilisant les erreurs de prédiction en tant qu'attributs texturaux et d'espaces couleur différents, et a été ensuite comparée à deux méthodes, paramétrique et non paramétrique, de classification des pixels.

ABSTRACT. This paper presents a new method for pixel classification in color texture images using the prediction error sequences generated by the linear prediction models in different color spaces. This method computes the class membership probability for each pixel of a given image. This probability uses the concept of clique potentials in a finite neighbourhood of the pixel. The proposed method is tested on real color textured images, by using the prediction error sequences as textural features in different color spaces. The results of the method are also compared to those of a parametric and non parametric pixel classification methods.

MOTS-CLÉS : Classification, modèles AR-DPNS et GMRF, Espace IHLS et L^*a^*b , texture couleur

KEYWORDS: Classification, AR-DPNS and GMRF models, IHLS and L^*a^*b space, color texture

.....

1. Introduction

La classification supervisée des textures couleur passe généralement par deux phases : une phase d'apprentissage qui permet d'extraire des attributs, ou descripteurs de textures, ce sont des vecteurs qui manifestent des variations importantes en passant d'une texture couleur à une autre ; et une phase de classification qui permet d'affecter chaque pixel ou région de l'image à la texture couleur qui lui correspond [1]. Selon les applications, il est important d'extraire les attributs et les espaces les plus pertinents pour décrire une texture couleur, pour cela, certains auteurs proposent de comparer les résultats de la classification obtenus en considérant différents types de descripteurs de textures associés aux différents espaces couleur [2,3,4]. La classification finale des pixels est effectuée soit par une méthode paramétrique, en adoptant l'hypothèse de la normalité de la distribution des pixels dans l'espace de leur descripteur [5] ; soit par une méthode non paramétrique reposant généralement sur le calcul de la distance du pixel en question avec ses plus proches voisins [2].

Dans ce papier, nous abordons la problématique de la classification des pixels d'une image texturée couleur en utilisant les erreurs de prédiction linéaire calculées dans deux espaces couleur (IHLS et $L^*a^*b^*$) [6,7] (Cf. section 2). Notre objectif est de proposer une nouvelle méthode de classification des pixels de l'image soumise à l'analyse à partir des pixels prototypes provenant de différentes textures couleur candidates (Cf. section 3). La méthode de classification développée est testée sur des images couleur texturées, utilisant les attributs proposés dans la section 2, et est comparée d'une part à la classification par la méthode des Kppv et d'autre part à la méthode de classification de Bayes (Cf. section 4).

2. Espace couleur et erreurs de prédiction linéaires

2.1. Espaces Couleur

Dans la plupart des applications utilisant des images couleur, les auteurs se contentent de travailler dans l'espace RGB. Cependant, l'emploi d'espaces couleur séparant les composantes chromatiques et achromatiques, comme l'espace $L^*a^*b^*$ [6] ou l'espace IHLS [7], permet souvent de révéler des éléments difficilement identifiables dans les plans R, G, et B. Les propriétés avantageuses des espaces IHLS et $L^*a^*b^*$, justifient leur choix dans la suite de ce papier.

L'idée consiste à construire une image contenant deux canaux. Le premier canal correspond aux valeurs de luminance, c'est à dire la composante « L » des espaces IHLS et $L^*a^*b^*$. Le second canal est obtenu à partir des 2 composantes chromatiques. Ces

composantes sont regroupées afin d'obtenir une valeur complexe représentative de la chrominance. Pour IHLS, ce deuxième canal est obtenu par l'expression suivante :

$$C = S \times \text{Exp}^{(j \times H)} \quad (1)$$

où H et S sont respectivement la teinte et la saturation. Pour l'espace $L^*a^*b^*$, le deuxième canal est calculé par :

$$C = a^* + jb^* \quad (2)$$

où a^* et b^* sont les composantes chromatiques de l'espace $L^*a^*b^*$. Une image couleur peut ainsi être représentée par un vecteur défini par :

$$x_n = \begin{bmatrix} I_n \\ c_n \end{bmatrix} \quad (3)$$

où les $I_n \in \mathfrak{R}$ et les $c_n \in \mathbb{C}$, avec $n = (n_1, n_2) \in \Lambda \subset \mathbb{Z}^2$, représentent respectivement le canal 'luminance' et le canal 'chrominance'. Λ est une grille finie 2D qui représente le support de l'image.

2.2. Erreurs de Prédiction linéaire

Un champ aléatoire 2D complexe multicanal peut être décrit par une famille de vecteurs aléatoires $X = (X_n)_{n \in \mathbb{Z}^2}$ de dimension P , P représentant le nombre de canaux. La prédiction linéaire de X_n associée à un support de prédiction $D \subset \Lambda$ est définie par le vecteur :

$$\hat{X}_n = - \sum_{m \in D} A_m (X_{n-m} - \mu) \quad (4)$$

avec $\mu = E(X_n)$, $\forall n \in \mathbb{Z}$, le vecteur moyen. Son erreur de prédiction E_n est donnée par:

$$E_n = (X_n - \mu) - \hat{X}_n. \quad (5)$$

$E = \{E_n\}_{n \in \mathbb{Z}^2}$ représente la famille de vecteurs aléatoires associés aux erreurs de prédiction. Dans le cas où le support de prédiction est causal, comme dans le cas du modèle AR QP (AutoRégressif Quart de Plan), ou AR DPNS (Autorégressif Demi-Plan Non Symétrique), la séquence d'erreur de prédiction est un bruit blanc. Tandis que pour un support de prédiction non-causal, par exemple le modèle de Gauss-Markov ou Gauss Markov Random Field (GMRF), la séquence d'erreur de prédiction est un bruit corrélé [7]. Dans la littérature, ces erreurs de prédiction linéaire ont été exploitées pour développer des méthodes de segmentation d'images texturées sur des images en niveaux de gris, où la classification spatiale des sites exploite une loi gaussienne, pour approcher la distribution des erreurs de prédiction, suivie d'un algorithme itératif de régularisation, utilisant le modèle de Potts [5].

Dans ce papier, nous utilisons une méthode non paramétrique de classification des pixels à partir des erreurs de prédiction vectorielle. Nous allons montrer, à travers des résultats expérimentaux l'aptitude de cette nouvelle méthode à classifier des images couleur texturées en utilisant les erreurs de prédiction linéaire et sans imposer une forme à la distribution de ces erreurs.

3. Classification à partir des erreurs de prédiction

3.1. Position du problème de classification des pixels

Classifier une image couleur texturée, revient à associer à chaque pixel de l'image un vecteur attribut couleur textural discriminant, calculé sous forme de paramètres spatiaux colorimétriques et statistiques. L'image est donc considérée comme un ensemble Γ de Q pixels q , où à chaque pixel ou 'site' est associé un vecteur $D_q \in \mathfrak{R}^4$ de quatre attributs représentant, dans le cas de notre analyse, les parties réelles et imaginaires des deux canaux de l'erreur de prédiction (Cf. section 2) calculées à partir de la luminance et de la chrominance [7,8]. La méthode non paramétrique de classification par les Kppv consiste à calculer, pour chaque pixel q candidat, la distance euclidienne entre les vecteurs d'attributs de ce pixel et tous les pixels (ou un pixel prototype) des textures modèles. Le pixel q est alors affecté à la classe qui minimise cette distance [2]. L'algorithme associé à cette méthode reste simple ; néanmoins, cette technique traite les pixels dans un ordre aléatoire, ce qui risque de provoquer des phénomènes de chaînage importants. Pour réduire considérablement ces phénomènes, une amélioration de cette technique consiste à déterminer, à chaque nouvelle affectation, le pixel le plus proche (en terme d'attributs) des prototypes des différentes textures, l'affecter à la classe de cette texture, puis le considérer comme un nouveau prototype, et ce jusqu'à classification de toute l'image [9]. Malgré les résultats performants de cette méthode, elle souffre du temps de calcul très lourd notamment pour les images de tailles importantes.

3.2. Modélisation du problème de classification

Dans l'espace \mathfrak{R}^4 des vecteurs d'attributs, le champ Γ des pixels q , ayant pour voisinage $V_q = \{r, d(D_q, D_r) < R\}$, R étant le rayon d'une boule de centre D_q , et de classe ω_0 représente l'ensemble des pixels de l'image soumise à l'analyse. Les pixels à l'intérieur de V_q peuvent être soit des pixels non-prototypes ; soit un mélange de pixels prototypes et non prototypes (Cf. Figure 1). Notre objectif est de classifier le pixel q dans l'une des classes $\omega_{k,k \neq 0}$ présentes dans son voisinage V_q .

Notre méthodologie de classification est basée sur le calcul des interactions entre pixels à l'intérieur du système de voisinage, à travers la fonction énergie $\phi^k(q,r)$ qui représente le potentiel d'interaction de la paire (q,r) en associant q à la classe ω_k :

$$\phi^k(q,r) = \frac{\gamma_{q,r}^k}{1 + d^2(D_q, D_r)} \quad (6)$$

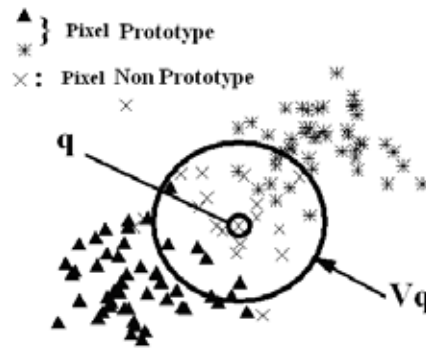


Figure 1 : Voisinage d'un pixel non prototype.

avec $\gamma_{q,r}^k = \begin{cases} 1 & \text{si } \omega_k \neq \text{classe}(r) \\ -1 & \text{si } \omega_k = \text{classe}(r) \end{cases}$, et où $d(D_q, D_r)$ représente la distance

euclidienne entre les vecteurs d'attribut du pixel q et du pixel r . Plus ces deux pixels sont éloignés, plus leur interaction mutuelle est faible. La classe la plus probable pour q est la classe qui minimise l'énergie globale du pixel q à l'intérieur de son voisinage V_q ,

ceci revient à maximiser la probabilité conditionnelle suivante :

$$P(\text{class}(q) = \omega_k / V_q) = \frac{\exp[-\sum_{(q,r) \in V_q} \phi^k(q,r)]}{\sum_{j=0}^K \exp[-\sum_{(q,r) \in V_q} \phi^j(q,r)]} \quad (7)$$

Cette probabilité représente le degré d'appartenance du pixel q à la texture k , $k=0,1,\dots,K$ [10].

3.3. Algorithme de classification des pixels

Initialisations :

Γ : image à classifier

Γ_p : images prototypes

$NP = \text{Card}(\Gamma)$
 R^0 : Rayon initial de la boule délimitant le système de voisinage
 ε : pas fonction de R^0
 \Rightarrow Tant que ($NP > 0$);
 \rightarrow Pour chaque pixel $q \in \Gamma$ et pour chaque classe $k=0,1,\dots,K$ calculer :
- $P(\text{classe}(q) = \omega_k / V_q)$ (Equation 7) \rightarrow $\text{classe}(q) = \text{Arg} [\text{Max}_{\omega_k \in \Omega} P(\text{classe}(q) = \omega_k / V_q)]$
- Si $\text{classe}(q) \neq \omega_0$ alors { $NP = NP - 1, \text{Count}++$ }
 \rightarrow Fin pour
- Si $\text{count} = 0$, $R^{t+1} = R^t + \varepsilon$;
 \Rightarrow Fin Tant que ;

4. Application à la classification des textures couleur

Nous souhaitons montrer l'aptitude de notre nouvelle méthode de classification à classifier des images texturées, à partir d'images prototypes représentant chacune une texture couleur caractéristique de l'image. Prenons pour cela les images de la figure 2 de $184 * 184$ pixels, synthétisées à partir de 2 et de 4 textures réelles extraites de la base VisTex [11]. A chaque pixel q de l'image à segmenter est associé un vecteur de quatre attributs représentant les parties réelles et imaginaires de l'erreur de prédiction, le détail des calculs de ces attributs est explicité dans [6,7]. Sur chacune des images, nous avons extrait les attributs de texture correspondant aux espace IHLS et $L^*a^*b^*$, en utilisant les deux modèles AR DPNS et GMRF (Cf. section 2.2 et [5, 6]). La classification, par la méthode proposée, des textures a été comparée aussi bien à la méthode des Kppv qu'à la méthode de Bayes [12] (Cf. Figure 2). L'analyse des résultats montre l'efficacité de la méthode proposée pour la classification des textures couleur ; en effet le meilleur taux d'erreur obtenu par cette nouvelle méthode est de 1.89 % (image 2 dans l'espace $L^*a^*b^*$ avec le modèle AR-DPNS) ; tandis que la méthode améliorée des Kppv a classifié ce même exemple avec un taux de 6.59%, et la méthode de classification de Bayes a donné un taux d'erreur de 4,81%. Notons aussi que le temps de calcul par la méthode proposée est nettement meilleur par rapport à la méthode des Kppv.

5. Conclusion

Dans ce papier, nous avons abordé le problème de la classification des pixels dans les images couleur texturées, à partir d'images prototypes. Nous avons utilisé deux modèles de prédiction linéaire, à savoir le modèle GMRF et le modèle AR-DPNS associés aux espaces couleur IHLS et $L^*a^*b^*$, pour tester et valider la méthode de classification proposée.

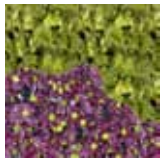
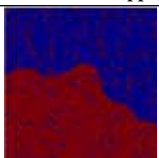
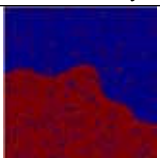
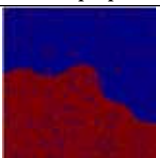
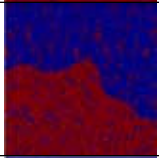
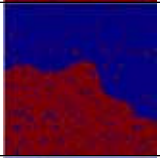
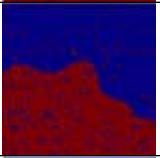
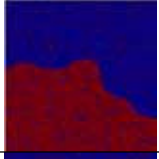
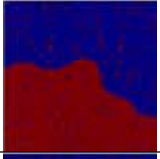
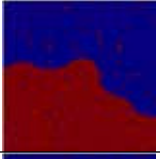
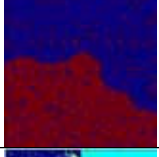
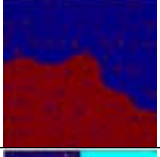
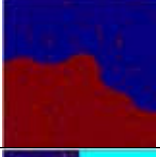

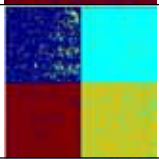

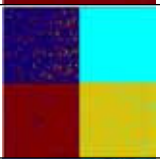
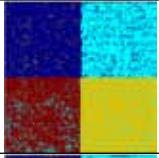
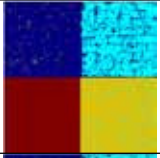
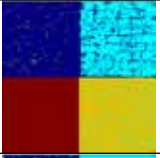
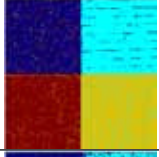
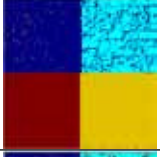
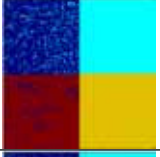
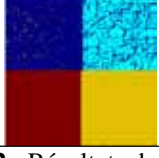
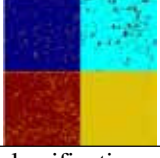

Images	modèle		Méthode des Kppv	Méthode de Bayes	Méthode proposée
 Image 1	GMRF	IHLS			
		CIE L*a*b*			
	AR-DPNS	IHLS			
		CIE L*a*b*			
 Image 2	GMRF	IHLS			
		CIE L*a*b*			
	AR-DPNS	IHLS			
		CIE L*a*b*			

Figure 2 : Résultats de la classification

Cette méthode consiste à calculer la probabilité d'appartenance de chaque pixel à une texture de l'image en utilisant l'énergie d'interaction du pixel en question avec ses pixels voisins dans l'espace des attributs. La méthode a été testée sur des données issues de textures couleur synthétiques, à travers lesquelles nous avons montré d'une part que la méthode n'est pas sensible à la méthode d'apprentissage utilisée, et d'autre part, elle est efficace comparée à la méthode des k plus proches voisins et à la méthode de Bayes. Comme perspective, nous envisageons d'introduire au niveau de la fonction énergie un terme de régularisation spatiale pour améliorer les résultats obtenus.

6. Bibliographie

- [1]: A.K. Jain, R.P.W. Duin, et J. Mao. Statistical pattern recognition : A review. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.22 n°1, pp.4–37, 2000.
- [2]: T. Mäenpää et M. Pietikäinen. Classification with color and texture : jointly or separately ?. *Pattern Recognition*, vol.37 n°8, pp.1629–1640, 2004.
- [3]: C. Palm. Color texture classification by integrative co-occurrence matrices. *Pattern Recognition*, vol.37 n°5, pp.965–976, 2004.
- [4]: Q. Xu, J. Yang, et S. Ding. Color texture analysis using the wavelet-based hidden markov model. *Pattern Recognition Letters*, vol.26, pp.1710–1719, 2005.
- [5]: Alata O., Ramananjarasoa C. Unsupervised textured image segmentation using 2-D quarter plane autoregressive model with four prediction supports. *Pattern Recognition Letters*, vol. 26, n° 8, pp.1069-1081-2005
- [6]: I.-U.-H. Qazi, O. Alata, J.-C. Burie, and C. Fernandez-Maloigne, Luminance-chrominance spatial structure model in psychovisual colour spaces. *In proceedings of AIC, 2009*.
- [7]: I.-U.-H. Qazi, O. Alata, J.-C. Burie, and C. Fernandez-Maloigne. Color spectral analysis for spatial structure characterization of textures in IHLS color space. *Pattern Recognition*, vol. 43, n° 3, pp. 663 – 675, 2010.
- [8]: A. Hanbury. A 3D-polar coordinate colour representation well adapted to image analysis. *In Proceedings of the Scandinavian Conference on Image Analysis*, pp.804-811, 2003.
- [9]: A. Moussa , A. Sbihi, J.-G.Postaire. A Markov random field model for mode detection in cluster analysis. *Pattern Recognition Letters*, vol. 29 pp.1197–1207,2008.
- [10]: M.Sbihi, A.Moussa, J. –G. Postaire, A.Sbihi. Approche markovienne pour la classification automatique non supervisée de données multidimensionnelles. *Journal Europeen des Systèmes Automatisés* vol. 39/9-10 - pp.1133-1154, 2005.
- [11]: <http://vismod.media.mit.edu/pub/VisTex>.
- [12] : B. Krishnapuram , A.-J Hartemink , L Carin , M.-A Figueiredo. A bayesian approach to joint feature selection and classifier design. *IEEE Trans Pattern Anal Mach Intell.* 26(9):1105-11, 2004.