

.....
.....
.....
.....
.....
.....
.....
.....
.....
.....

CLASSIFICATION DES TEXTURES

Application à la Classification d'Images Médicales

A. Moussa¹, A. Sbihi² & J.-G. Postaire³

(1) Laboratoire LabTIC, BP 1818, ENSAT, Tanger, Maroc

(2) Laboratoire LASTID, Université Ibn Tofail, Kenitra, Maroc

(3) Laboratoire LAGIS, Université des Sciences et Technologies de Lille, France

.....

RÉSUMÉ. Les approches statistiques locales de classification automatique considèrent les noyaux des classes comme des régions à forte concentration d'observations. Pour classifier toutes les observations disponibles, ces méthodes considèrent les observations situées à l'intérieur des noyaux des classes comme des observations prototypes. Les observations restantes sont finalement assignées à leurs classes en utilisant les prototypes les plus proches. Dans le cas des classes à un degré de chevauchement important ou des classes non linéairement séparables, cette procédure de classification est non triviale.

Le présent papier propose une nouvelle méthode de classification qui tient compte de l'information contextuelle de l'observation. Basé sur les outils Markoviens, cette méthode maximise la probabilité conditionnelle de Gibbs pour classifier progressivement les observations situées entre et/ou à l'extérieur des noyaux des classes. L'application de cette nouvelle procédure à la classification d'images texturées démontre son efficacité et son importance pour caractériser les altérations des textures osseuses.

ABSTRACT. In the mode seeking approaches for statistical pattern classification, modes are usually considered as regions of the data space characterized by high densities of data points. To assign the available observations to the so-detected clusters, these approaches use the input observations falling into the detected modes as prototypes. The remaining observations are finally assigned to the clusters attached to their nearest (Euclidean) neighbors among these prototypes. In the overlapped case or non linearly separable classes, this grouping procedure is not trivial.

The present paper proposes a new method of classification which takes into account the contextual information of the observation. Based on Markovian tools, this method maximizes the Gibbs conditional probability to classify progressively the observations standing between detected cores of clusters. Application of this new procedure to textured medical image classification demonstrates its efficiency and its importance to characterize bone texture alteration

MOTS-CLÉS : Classification, champ de Gibbs, Analyse de Texture.

KEYWORDS: Classification, Gibbs Field, Texture Analysis.

.....

.....
.....
.....
.....
.....
.....
.....
.....
.....
.....

1. Introduction

Les approches statistiques locales de classification automatiques se déroulent généralement en deux phases [1] : la 1^{ère} phase, phase d'apprentissage, consiste à la détection des noyaux des classes en présence dans l'échantillon qui contiennent les observations prototypes. La 2^{ème} phase réalise la classification 'proprement dite' de toutes les observations de l'échantillon à partir des observations prototypes identifiées lors de la 1^{ère} phase.

Plusieurs approches ont été développées dans la littérature pour la mise en évidence des noyaux des classes [2,3,4]. Pour tester leurs efficacités, on utilise la notion de taux d'erreur, après la phase de classification, en faisant appel généralement à la méthode des k plus proches voisins [5]. Il en résulte que dans le cas des distributions présentant un degré important de chevauchement ou des distributions non linéairement séparables, un taux d'erreur élevé pourra être aussi lié à la méthode de classification utilisée. Ce problème se pose surtout dans le cas des observations de très grande taille et à dimension élevée, tels sont les cas de la classification des images texturées à partir des paramètres de textures.

Dans l'objectif d'améliorer la phase de classification, ce papier propose une méthode originale de classification des observations à partir des noyaux des classes basée sur un concept à la fois métrique et probabiliste (section 2). L'application à la classification d'images texturées (section 3) permettra de valider cette nouvelle méthode, et montrer son intérêt pour les problèmes d'aide à la décision en diagnostic médicale.

2. Extraction des Observations Prototypes

Soit Γ l'ensemble des Q observations soumis à l'analyse et $D_q = (d_{q,1}, d_{q,2}, \dots, d_{q,n}, \dots, d_{q,N})^T$ un élément appartenant à Γ ; les $d_{q,n}$ représentent les coordonnées de l'observation D_q dans l'espace \mathcal{R}^N . Sans perte de généralité, considérons l'exemple de la figure 1, généré artificiellement à partir de deux distributions normales. La méthode Markovienne non supervisée [4] a permis la mise en évidence de deux noyaux dont les observations prototypes correspondantes sont illustrées sur la figure 2. L'échantillon Γ est alors composé de deux sous-ensembles :

- Γ_p : l'ensemble des observations prototypes représenté sur la figure 2
- Γ_{np} : l'ensemble des observations non prototypes restantes.

Soit X un champ aléatoire indexé sur l'ensemble Γ des observations. Le champ X est labellisé de la façon suivante :

$$-(X_q = C_1 \text{ ou } X_q = C_2) \Leftrightarrow D_q \in \Gamma_p$$

$$-X_q = C_0 \Leftrightarrow D_q \in \Gamma_{np}$$

Avec C_0 une classe non encore définie et C_1, C_2 les labels relatifs aux deux noyaux présents dans l'échantillon.

La structure du champ X reflète une dépendance de voisinage traduite par l'hypothèse Markovienne suivante :

- La probabilité de toute réalisation de X est non nulle : $P(X) > 0$
- $P(X_q = C_k / X_r = C_{k'}, D_r \in \Gamma) = P(X_q = C_k / X_r = C_{k'}, D_r \in V_q)$

avec V_q le système de voisinage sphérique de rayon R centré en D_q (Cf. figure 3).

Les observations à l'intérieur de V_q peuvent être soit des observations prototypes soit des observations non prototypes (Cf. figure 3).




Figure 1. Observations à Classer




Figure 2. Observations Prototypes

Pour classer l'observation D_q , l'approche proposée consiste tout d'abord à calculer l'énergie conditionnelle de Gibbs [6] donnée par :

$$U(X_q = C_k / X_r, D_r \in V_q) = \sum_{D_r \in V_q} \varphi(X_q = C_k, X_r) \quad (1)$$

$\varphi(X_q = C_k, X_r)$, appelée fonction de potentiel, tient compte à la fois de la nature des observations et de leurs distances mutuelles. Sur le modèle proposé par [6], son expression explicite est :

$$\varphi(X_q = C_k, X_r = C_{k'}) = \frac{\gamma_{q,r}}{1 + \text{dist}^2(D_q, D_r)} \quad \text{où } \gamma_{q,r} = \begin{cases} 1 & \text{si } C_k \neq C_{k'} \\ -1 & \text{si } C_k = C_{k'} \end{cases} \quad (2)$$

et $\text{dist}(D_q, D_r)$ représente ici la distance Euclidienne entre l'observation D_q et une observation D_r de son voisinage sphérique (Cf. figure 3).

L'étiquette de l'observation D_q sera alors celle qui maximise la probabilité conditionnelle de Gibbs donnée par :

$$P(X_q = C_k / X_r, D_r \in V_q) = \frac{\exp[-U(X_q = C_k / X_r, D_r \in V_q)]}{\sum_{j=0}^2 \exp[-U(X_q = C_j / X_r, D_r \in V_q)]} \quad (3)$$

Algorithme itératif de classification

⇒ Initialisations $(\Gamma_p, \Gamma_{np}, X, R^0, \varepsilon)$

⇒ Tant que $(\text{card}(\Gamma_{np}) \neq 0)$;

• pour chaque observation D_q de Γ_{np} ;

— pour chaque classe C_k ;

- calcul de $U^t(X_q = C_k / X_r, D_r \in V_q)$ et $P^t(X_q = C_k / X_r, D_r \in V_q)$;

- calculer $C_j = \text{Arg} \left(\text{Max}_{k=0,1,2} P^t(X_q = C_k / X_r, D_r \in V_q) \right)$;

si $C_j \neq C_0$ alors $X_q = C_j$ et $\text{card}(\Gamma_{np}) = \text{card}(\Gamma_{np}) - 1$;

• $R^{t+1} = R^t + \varepsilon$;

⇒ Fin Tant que ;

L'application de l'algorithme proposé pour la classification des données de la figure 1 à partir des prototypes de la figure 2, permet d'assigner, après 7 itérations, la totalité des observations avec un taux d'erreur de 2 % (Cf. figure 4). Pour cet exemple la méthode des k plus proche voisins a conduit à un taux de 3.25 %. Ces résultats montrent l'intérêt de la méthode proposée dans le cas de classes enchevêtrées. Notons que l'exemple présenté est un exemple bidimensionnel illustratif, dans la suite, nous allons appliquer notre algorithme à des données multidimensionnelles non linéaires et enchevêtrées, telles sont les données issues des images texturées.

3. Application à l'Analyse d'Images Texturées

3.1. Analyse de Textures Synthétiques

Nous proposons en premier lieu d'appliquer la méthode proposée sur des images de textures synthétiques. L'image à traiter est synthétisée à partir de deux motifs de l'album brodatz [7] (Cf. figure5, Im1, Im2, Im3). Les données se présentent sous forme d'une

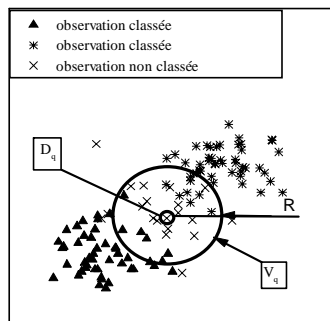


Figure 3. Voisinage d'une observation non prototype




Figure 4. Observations classifiées

matrice dont les lignes représentent les pixels et les colonnes sont associées aux cinq paramètres de textures de Haralick [8] calculés sur la base de la matrice de cooccurrence, à savoir l'énergie, l'entropie, l'homogénéité, la corrélation et la variance. Les cinq paramètres ont été choisis en observant leurs efficacités de discriminer des textures aléatoires et fines possédant des propriétés de ressemblances avec les propriétés des images médicales qui seront traitées dans la suite. Les résultats reflétés par le taux d'erreur et la matrice de confusion (Cf. Tableau 1) montre l'efficacité de la méthode proposée. Ces résultats sont confirmés par les images classifiées de la figure 5.

3.2. Analyse d'Images Médicales

Dans le type d'analyse qui nous intéresse. On dispose de deux images IRM de la même pièce anatomique osseuse correspondant à deux sujets couvrant des conditions idéales pour la comparaison telles que age, sexe, condition de vie, alcool, tabac, ..etc. Sur un sujet, les analyses densimétriques ont montré l'absence de pathologies liées à l'ostéoporose, c'est un sujet sein, il servira comme référence au cours des analyses. Par contre, pour le deuxième sujet, l'analyse densimétrique n'était pas concluante. Une

étude de la microarchitecture de l'os s'avère alors nécessaire pour dépister une éventuelle dégénérescence de l'os due à une pathologie ostéoporotique [9].

Sur les deux images des deux sujets on s'intéresse à une région bien précise appelée ROI (Region Of Interest). Le dépistage par analyse texturale de l'os consiste à extraire le descripteur de la texture du ROI du sujet sain et le comparer au descripteur du ROI du sujet en question. Autrement dit, le problème de l'analyse est de quantifier les variations du descripteur de la texture en passant d'une texture de référence à une texture à analyser. Pour cela, notre démarche consiste à synthétiser une seule image à partir de deux ROI. La classification de l'image synthétique en deux classes permettra de dévoiler la présence ainsi que la taille d'une dégénérescence si elle existe.

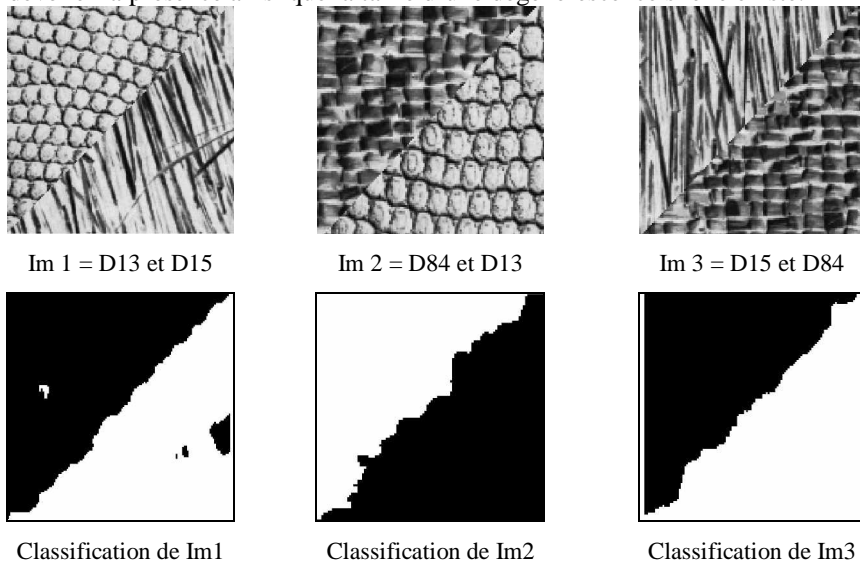


Figure 5. Classification des textures issues de l'album de Brodatz

L'algorithme de classification proposé est appliqué sur les images texturées relatives à deux sujets pathologiquement différents. Ces images sont assemblées respectivement par collage diagonal, vertical et horizontal (Cf. figure 6, Im4, Im5, Im6). La classification des textures par la méthode proposée (Cf. figure 6) a permis de séparer la texture correspondante au sujet sain de celle liée au sujet pathologique. Ces résultats sont confirmés par le résultat de l'évolution des valeurs moyennes des descripteurs de la texture (Cf. tableau 1) qui manifestent des variations importantes en passant d'une texture à une autre. Le taux d'erreur et la matrice de confusion apportent des informations supplémentaires sur la déformation micro architectural de l'os. Ces

informations prouvent la présence de changements dans la structure trabéculaire de l'os indiquant une pathologie ostéoporotique.

4. Conclusion

Dans ce papier, nous avons développé une nouvelle méthode de classification des données à partir d'observations prototypes, utilisé dans le cas de donnée à grande taille. Cette méthode utilise la notion de l'énergie et de la probabilité conditionnelle de Gibbs pour affecter, de façon itérative, chaque observation présente à l'analyse à une classe présente dans l'échantillon. La méthode a été testée sur des données synthétiques et comparée avec la méthode des k plus proches voisins. Vue l'aspect stochastique de la méthode, son intérêt réside surtout dans l'analyse de phénomènes aléatoires telles sont les données issues des images texturées, notamment les images IRM de textures osseuses. L'application de cette nouvelle méthode pour la discrimination entre sujet pathologique et sujet sein à travers la caractérisation des paramètres de chaque texture, montre que les statistiques issues de la classification apporte des informations de grande importance sur la structure de l'os et sur sa pathologie.

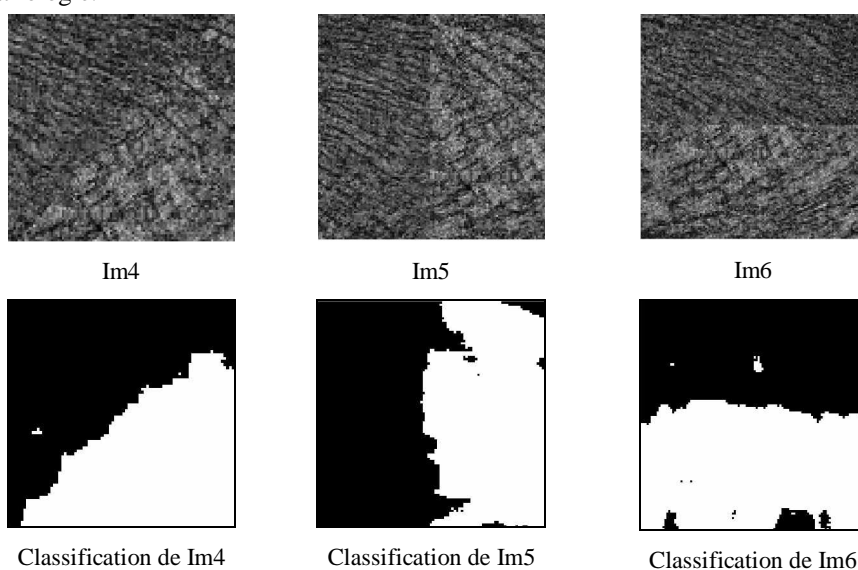


Figure 6. Classification des textures issues des images osseuses

| Paramètres de texture | | Descripteur de la Texture | | | | | Matrices de Confusion | Taux d'Erreur |
|-----------------------|----------|---------------------------|-------|-------|-------|------|-----------------------|---------------|
| | | P1 | P2 | P3 | P4 | P5 | | |
| Images de synthèse | Classe 1 | 30.98 | 73.54 | 73.43 | 7869 | 16.7 | 9786 18 | 1.88 % |
| | Classe 2 | 78.51 | 131.1 | 147.3 | 146.9 | 7.15 | 367 10278 | |
| Images Médicales | Classe 1 | 150.2 | 164.3 | 62.45 | 74.8 | 14.2 | 10024 566 | 5.10 % |
| | Classe 2 | 63.25 | 66.33 | 154.7 | 159.4 | 6.96 | 272 9587 | |

Tableau 1. Résultats de la Classification des textures synthétiques et réelles

Remerciements

Ce travail entre dans le cadre du projet CANOST financé le Centre de Recherche Et d'Application en Traitement de l'Image et du Signal, les auteurs remercient Mrs. P. Duboit et X. Marchandise de l'Institut de Technologie Médicale de Lille d'avoir fournit les images de tests et de leurs discussions et conseils pour les analyses.

5. Bibliographie

- [1] : J. KITTLER 'A Local Sensitive Method for Cluster Analysis' *Pattern Recognition*, vol. 8, pp. 23-33, 1976
- [2] : A. Touzani & J. -G. Postaire, 'Mode detection by relaxation' *IEEE Trans. Pattern Anal. and Machine Intell.*, 10 (6) pp. 970-978, 1988.
- [3] : J. -G. Postaire, R. -D. Zhang & C. Botte-Lecocq, 'Cluster Analysis by Binary Morphology' *IEEE. Trans. Pattern Anal. and Machine Intell.*, vol. 15 (2), pp. 170-180, 1993.
- [4] : A. Moussa, A. Sbihi, and J.-G. Postaire, 'Classification Automatique par Extraction des Noyaux des Classes Utilisant une Approche Markovienne' *APII-JESA, Hermes*, vol. 35 (9), pp. 1073-1087, 2001
- [5] : R.O. Duda, P.E. Hart and D. G. Stork, '*Pattern Classification*' Wiley Interscience Publication, Second Edition, 2001
- [6] : S. Geman and D. Geman, 'Stochastic Relaxation, Gibbs Distribution and the Bayesian Restoration of Images' *IEEE Trans. Pattern Anal. and Machine Intell.*, 6 (1984) 721-741.
- [7] : P. Brodatz, '*Textures: A photographic album for artists and designers*' New York : Dover, NY, 1996.
- [8] : L. S. Davis, S. A. Johns and J. K. Aggarwal, 'Texture Analysis Using Generalized Co-Occurrence Matrix' *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 3, pp. 251-259, 1996.
- [9] : B. Cortet, P. Duboit, N. Boutry, P. Bourel, A. Cotton and X. Marchandise, 'Image Analysis of the Distal Radius Trabecular Network Using Computed Tomography' *Osteoporosis international*, vol. 9, pp. 410-419, 1999.