



Classification des Images Couleurs par association des Transformations Morphologiques aux Cartes de Kohonen

M. Talibi-Alaoui, R. Touahni et A. Sbihi

Laboratoire Image et Reconnaissance des Formes,
Université Ibn Tofail, FSK, BP. 133, 14000, Kénitra, Maroc.

talibialaouim@yahoo.fr, sbihi@univ-ibntofail.ac.ma

RÉSUMÉ. Ce travail propose une méthode de classification non supervisée des images couleurs, basée sur l'utilisation des cartes auto-adaptatives de Kohonen et de la morphologie mathématique. L'échantillon d'observations à trois dimensions, constitué des composantes couleurs des pixels de l'image, est d'abord projeté sur une carte de Kohonen dont l'information est représentée par un estimateur non paramétrique de la fonction de densité de probabilité sous-jacente à la distribution dans l'espace tridimensionnel des vecteurs poids résultant de l'apprentissage du réseau. Sous l'hypothèse que chaque région modale de cette fonction de densité correspond à une région homogène dans l'image couleur, la seconde étape de la méthode proposée consiste en une exploitation originale de la technique de la ligne de partage des eaux pour une partition de la carte de Kohonen en des régions connexes sans passer par aucune procédure de seuillage. Les observations situées dans les régions homogènes ainsi localisées dans la carte constituent des prototypes de classes présentes dans l'image et sont utilisées dans une règle d'assignation pour la classification de tous les pixels.

MOTS-CLÉS : Image Couleur, Classification, Réseaux de Kohonen, Ligne de partage des eaux

ABSTRACT. This work proposes a new method for unsupervised colour image classification, which is based on both Kohonen maps and mathematical morphology. The sample of observations, constituted by image pixels with 3 colour components in the colour space, is at first projected into a Kohonen map. This map is represented by the underlying probability density function (pdf) estimated, by a non-parametric technique in the 3-dimensional space, from the weight vectors resulting of the learning process. Under the assumption that each modal region of the underlying pdf corresponds to a one homogenous region in the colour image, the second step of the process understanding consists to an extraction, in the Kohonen map, of the modal regions of the pdf as connected components without using any thresholding procedure. That is done by making concepts of morphological watershed transformations suitable for modal domains detection. The observations falling in the so localised homogenous region in the image are considered as prototypes and are then used in the clustering procedure by means of an assignment rule.

KEYWORDS: Colour Image, Classification, Kohonen Network, Watershed transformation

1. Introduction

La qualité de l'interprétation d'une image couleur dépend fortement de celle de la segmentation. Parmi les méthodes de segmentation, certaines s'intéressent à chercher les régions connexes homogènes dans l'image. Ce traitement de bas niveau sert, entre autres, de base à l'identification des classes présentes dans l'image, et par conséquent à la classification qui consiste à assigner chaque pixel de l'image à l'une des classes ainsi identifiées.

Plusieurs algorithmes ont été proposés dans ce sens [1, 2, 3, 4, 5]. Certains nécessitent un seuillage de l'histogramme ou le réglage de certains paramètres, d'autres sont limités aux cas où les différentes classes correspondent à des nuages séparables dans l'espace de mesure tandis que d'autres ne prennent pas en compte les relations géométriques des pixels dans l'image.

Dans ce travail, nous proposons une nouvelle approche de classification automatique non supervisée des images couleurs, basée sur des concepts connexionnistes et morphologiques. Les attributs couleurs de chaque pixel de l'image forment un nuage d'observations dans l'espace couleur utilisé. Pour aider à découvrir les différentes classes présentes dans ce nuage d'observations tridimensionnelles, nous proposons d'effectuer, comme première phase de traitement, la projection de ces observations sur une carte bidimensionnelle de Kohonen [6, 7, 8]. L'information contenue dans chaque maille de cette carte est représentée par une valeur de la fonction de densité de probabilité (fdp) estimée, par une





procédure non paramétrique [9], à partir de la distribution dans l'espace tridimensionnel des vecteurs poids issus de l'apprentissage du réseau de neurones.

Sous l'hypothèse que chaque maximum régional [10, 11] de cette fdp marque une région modale de cette fonction, laquelle correspond à une région homogène dans l'image, la deuxième étape du traitement consiste en une extraction automatique des régions modales de la fdp en composantes connexes individualisées. Cette extraction repose sur l'exploitation de la technique de ligne de partage des eaux, généralement utilisée pour la segmentation d'images numériques par morphologie mathématique [12, 13, 14].

Enfin, la phase de classification consiste à prendre les vecteurs poids correspondants aux régions modales ainsi détectés comme des prototypes des régions homogènes présentes dans l'image. Les poids correspondants à chacun de ces prototypes sont à la base de l'assignation de tout pixel de l'image à l'une des classes en présence.

2. Représentation de l'information couleur de l'image sur une carte de Kohonen

Tout processus de classification commence par une étape d'acquisition des observations qui consiste à déterminer les attributs caractérisant aux mieux les objets.

Dans le cadre de l'approche ici proposée, l'échantillon d'observations est constitué des pixels d'une image couleur. Les composantes couleurs de chaque pixel, prises dans le système colorimétrique utilisé, définissent les attributs des observations dans un espace à trois dimensions.

2. 1. Principe de la carte auto-adaptative de Kohonen

Soit $\Gamma = \{X_1, X_2, \dots, X_q, \dots, X_Q\}$ un échantillon constitué de Q observations définies dans un espace à N dimensions telles que $X_q = [X_{q,1}, X_{q,2}, \dots, X_{q,n}, \dots, X_{q,N}]^T$, $q=1, 2, \dots, Q$. La structure du réseau de Kohonen est constituée de deux couches. La première, appelée couche d'entrée, est composée de N neurones représentant les N attributs d'une observation X_q . La couche de sortie, ou couche compétitive, est composée d'un nombre M de neurones régulièrement répartis sur une carte (cf. figure 1).

Les neurones de la première couche sont connectés à ceux de la deuxième couche. Chaque connexion d'un neurone d'entrée j vers un neurone de sortie m a le vecteur poids $W_{m,j}$. Ainsi, chaque neurone de sortie m a le vecteur poids

$$W_m = [W_{m,1}, W_{m,2}, \dots, W_{m,n}, \dots, W_{m,N}]^T \quad (\text{cf. figure 1}).$$

Chaque neurone de la couche de sortie est donc caractérisé par sa position relative sur la carte et par son vecteur poids dans l'espace de représentation des observations. L'apprentissage du réseau consiste, à chaque présentation à l'itération t d'une observation $X_q(t)$ à l'entrée du réseau, à sélectionner le neurone gagnant, autrement dit celui dont le vecteur poids est le plus proche de cette observation. Le vecteur poids du neurone gagnant et ceux des neurones voisins sur la carte sont alors modifiés en fonction de l'observation présentée au réseau. Cette disposition des neurones et cette technique d'apprentissage permettent aux neurones voisins sur la carte d'être sensibles à des observations voisines dans l'espace d'origine : c'est le phénomène d'auto-adaptation décrit par Kohonen [6]. A la fin de cette étape, chaque neurone devient sensible à une zone de l'espace de représentation des observations et son vecteur poids converge vers le barycentre des observations présentes dans cette zone.

Le voisinage de rayon r d'un neurone m est défini par l'ensemble des neurones m' tel que :

$$V(m,r) = \left\{ m' \in [0, M[, m' \neq m / d(U_m, U_{m'}) \leq r \right\}$$





où $d(U_m, U_{m'})$ désigne la distance Euclidienne entre les vecteurs U_m et $U_{m'}$ qui sont les positions respectives des neurones m et m' sur la carte.

A la présentation au réseau de chaque observation $X_q(t)$, le vecteur poids du neurone gagnant, noté m^* , et ses voisins sont modifiés pour chaque itération t tels que :

$$\begin{aligned} W_m(t) &= W_m(t-1) + a(t) \cdot [X_q(t) - W_m(t-1)] && \text{si } m=m^* \\ W_m(t) &= W_m(t-1) + a(t) \cdot h(m^*, t) \cdot [X_q(t) - W_m(t-1)] && \text{si } m \in V(m^*, r(t)) \\ W_m(t) &= W_m(t-1) && \text{si } m \notin V(m^*, r(t)) \text{ et } m \neq m^* \end{aligned}$$

où :

- ♦ $W_m(t)$ est le vecteur poids du groupe de connexions des neurones de la couche d'entrée vers le $m^{\text{ème}}$ neurone de la couche de sortie, à l'itération t .

- ♦ $r(t)$ est le rayon de voisinage ou d'interaction qui dépend du rang t de l'itération considérée.

- ♦ $a(t)$ est le coefficient d'apprentissage. Il peut être une fonction hyperbolique, une fonction exponentielle ou aussi une fonction linéaire de paramètre itération t .

- ♦ m^* est le neurone gagnant défini par : $m^* = \text{Arg} \min_m [d(X_q(t), W_m(t))]$

- ♦ $h(m^*, t)$ est la fonction d'interaction définie par : $h(m^*, t) = \exp\left(-\frac{d^2(U_m, U_{m'})}{2r^2(t)}\right)$.

2. 2. Application à la représentation d'image couleur

2. 2. 1. Phase d'apprentissage

Dans cette application nous avons utilisé une image couleur synthétique de taille 64×64 codée sur 24 bits (cf. figure.2).




Fig 1. Réseau de Kohonen



Fig 2. Image couleur de synthèse




Fig 3. Représentation des pixels dans l'espace RVB

Chaque pixel de l'image est représenté par ses trois composantes colorimétriques RVB dans un espace à trois dimensions (cf. figure.3). Les 4096 observations ainsi représentées dans l'espace RVB constituent l'échantillon $\Gamma = \{X_1, X_2, \dots, X_q, \dots, X_{4096}\}$ pour l'apprentissage du réseau. Afin d'avoir une bonne illustration de la projection de ces observations sur une carte de Kohonen, nous avons utilisé une carte de taille 25×25 .





Lors de la phase d'apprentissage, les observations sont présentées séquentiellement une par une à l'entrée du réseau de manière aléatoire et sans remise. Nous avons modélisé le coefficient d'apprentissage (cf.figure.4) par une fonction exponentielle du paramètre itération (t) qui décroît, lors de l'apprentissage, vers zéro quand t augmente, telle que :

$$a(t) = \alpha_1 e^{-\alpha_2 t} + \alpha_3$$

Soit T le nombre d'itérations estimées pour assurer l'apprentissage du réseau. En choisissant les valeurs 0.8 et 0.05 respectivement comme des valeurs maximale et minimale du coefficient d'apprentissage a(t), et en cherchant à ce que a(t) atteigne la valeur 0.1 en (2T)/3, on obtient :

$$a(t) = 0,75 \exp(-8,12 \cdot 10^{-5} t) + 0.05$$




Fig 4. Fonction d'apprentissage




Fig 5. Evolution de r(t)




Fig 6. Distribution des vecteurs poids

Le rayon de voisinage r(t) introduit dans la fonction d'interaction $h(m^*, t)$ est une fonction décroissante (cf.figure.5) qui diminue toutes les $n_r Q$ itérations, où n_r est le nombre d'époques à rayon constant et Q le nombre d'observations de l'échantillon qui est de 4096. Le rayon r(t) s'exprime alors par :

$$r(t) = \begin{cases} r(t-1) - 1 & \text{si } t \bmod(n_r Q) = 0 \text{ et } r(t) \geq 1 \\ \varepsilon & \text{si } t \bmod(n_r Q) = 0 \text{ et } r(t) < 1 \\ r(t) & \text{sinon} \end{cases}$$

L'apprentissage a été effectué durant 10^5 itérations. Le phénomène de la convergence des vecteurs poids $W_m(t)$ vers les zones à fortes concentrations des observations est observé sur la figure 6.

2. 2. 2 Représentation numérique de la carte de Kohonen

La carte de Kohonen, qui constitue la couche de sortie du réseau (cf. figure 1), peut représenter l'information issue de l'apprentissage du réseau sous divers aspects [15]. Quelque soit le type de paramètre utilisé pour représenter l'information au sein de chaque maille de la carte, un examen visuel de cette dernière permet souvent de distinguer des zones claires, correspondantes aux régions à forte concentration des vecteurs poids dans leur espace de représentation, délimitées par des lignes sombres correspondantes aux régions à faible concentration des vecteurs poids, ou l'inverse. Ainsi, la visualisation de la carte de Kohonen est un support privilégié pour l'analyste averti qui peut l'exploiter pour prendre une décision concernant le nombre de classes présentes dans l'échantillon et procéder à une classification interactive. Or quelque soit le type adopté pour la représentation de la carte, celle-ci gagnerait plus d'intérêt si elle pourrait être exploitée par des procédures de classification automatique non supervisée, i.e. sans aucune intervention de l'analyste dans la prise de décision.





Dans ce contexte, nous avons pensé, dans le présent travail, à extraire de manière automatique, en composantes connexes individualisées, les différentes zones de la carte qui correspondent à des régions à forte concentration des vecteurs poids dans leur espace d'origine. La procédure proposée étant basée sur des opérateurs de la morphologie mathématique numérique [14, 16, 17, 18], nous allons alors adopter une représentation numérique de la carte de Kohonen.

Ainsi, les informations issues de l'apprentissage du réseau sont représentées par la fonction de densité de probabilité (fdp) sous-jacente à la distribution des vecteurs poids W_m dans leur espace de représentation, estimée par la technique non paramétrique de Parzen [9], telle que :

$$p(W_m) = \frac{1}{Q} \sum_{q=1}^Q \frac{1}{V[D(W_m)]} \Omega\left(\frac{W_m - X_q}{h_Q}\right)$$

où : ♦ Ω est la fonction noyau définie par : $\Omega(X) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}X^T X\right)$

♦ $D(W_m)$ est le domaine d'estimation, représenté dans notre cas par une sphère de rayon h_Q , centrée au point d'estimation W_m . Le volume $V[D(W_m)]$ est alors tel que :

$$V[D(W_m)] = \frac{\pi^{\frac{N}{2}}}{\Gamma\left(\frac{N}{2} + 1\right)} \quad \text{avec} \quad \Gamma\left(\frac{N}{2} + 1\right) = \frac{(N+1)! \sqrt{\pi}}{2^{(N+1)} \left(\frac{N+1}{2}\right)!}$$

Chaque neurone m de la couche de sortie, ou encore chaque maille de la carte de Kohonen, porte ainsi l'information relative à la valeur $p(W_m)$ de la fdp estimée au point W_m (cf. figure 7). Une autre illustration de cette carte peut être fournie par le graphe de la fdp sous-jacente (cf. figure 8).



Fig 7. Carte de Kohonen



Fig. 8 Graphe de la fdp

3. Détection des modes de la fdp par la technique de la lpe

L'analyse du graphe de la fdp, schématisé dans la figure 8, permet de confirmer que les maxima de cette fonction correspondent aux zones à forte concentration des vecteurs poids issus de l'apprentissage dans leur espace de représentation. A ce stade de traitement, notre objectif reste à chercher à localiser ces maxima de manière automatique. Pour cela, nous postulons que chaque région modale de la fdp est une composante connexe dans la carte de Kohonen, résultante d'un prolongement, ou encore d'une extension dans cette carte d'un maximum régional [12] de cette fonction. Ainsi, chaque maximum régional peut être considéré comme un marqueur de la région modale qui lui est associée.





Sous cette hypothèse, nous pouvons alors faire appel à la technique de ligne de partage des eaux (lpe) [13, 14]. En effet, cette technique, très utilisée en segmentation d'image par morphologie mathématique, consiste dans sa première étape de traitement à marquer les minima régionaux de la fonction, et de procéder ensuite à une extension homotopique et géodésique [14, 18] de ces marqueurs jusqu'à construction des bassins versants et des digues les séparant.

On peut alors envisager d'appliquer cette transformation à la fonction opposée de $p(W_m)$, notée $f(W_m)$; les maxima de $p(W_m)$ deviennent alors des minima de $f(W_m)$. Les bassins versants résultants de l'application de la lpe sur la fonction $f(W_m)$ formeront, dans le graphe de la fonction opposée à la fonction résultante, des régions qui sont, par dualité, des extensions géodésiques et homotopiques des maxima régionaux de $p(W_m)$, matérialisant ainsi les régions modales de la fdp. Ces régions sont séparées par des lignes et sont facilement extraites en composantes connexes par le biais d'une simple transformation morphologique.

La figure 9 illustre le graphe de la fonction résultante de cette technique, appliquée à la version filtrée par une ouverture numérique [16] de la fonction $p(W_m)$. Ce même résultat est schématisé par une représentation binaire sur la carte de Kohonen (cf. figure 10), où les régions modales de la fdp sont bien représentés par des composantes connexes individualisées. Les régions marquées par 2, 3, 4 et 5 représentent respectivement les couleurs bleu, jaune, rouge et verte, alors que les régions marquées par 1 représentent le fond noir de l'image. On voit que ce fond a été représenté par 3 régions modales. Cela est dû au fait que la lpe, qui est une procédure d'analyse locale, reste sensible à toute irrégularité dans la fdp sous-jacente et risque ainsi de diviser une région homogène en des sous-régions. Cela représente toutefois un avantage dans le type d'analyse ici proposé surtout pour des images réelles complexes puisque nous ne partons pas de l'hypothèse que toute région modale de la fdp représente une classe au sein de l'image, mais plutôt de l'hypothèse que toute région modale représente une région homogène dans l'image, laquelle peut être une classe ou une sous classe dans l'image.



Fig 9. Régions modales de la fdp




Fig 10. Identification des classes sur la CK

4. Classification des pixels de l'image

Sous l'hypothèse que les régions modales détectées correspondent à des régions homogènes présentes dans l'image et qu'une classe peut être représentée sur la carte de Kohonen par une ou plusieurs régions homogènes dans l'image, les points constituant les régions modales sont considérés comme des prototypes des classes présentes dans l'image (cf. figure 11), et sont à la base de l'assignation de tout pixel de l'image à l'une des classes, moyennant la distance euclidienne sur la carte (cf. figure 12).





Fig 11. Représentation des prototypes dans l'image



Fig 12. Image après classification

5. Application à l'image réelle

Pour illustrer les performances de l'approche proposée, nous l'avons appliquée à une image réelle de taille 128*128 codée sur 24 bits où les différentes classes présentent un degré de chevauchement important dans l'espace couleur choisi IHS.



Fig 13. Image peppers




Fig 14. Représentation des pixels dans l'espace IHS



Fig 15. Carte de Kohonen



Fig 16. Extraction des régions modales par la lpe



Fig 17. Représentation des prototypes



Fig 18. Image après classification

chaque pixel de l'image (cf. figure 13) est représenté par ses trois composantes IHS (cf. figure 14). Les 16384 observations constituent l'échantillon Γ pour l'apprentissage du réseau de Kohonen. Nous avons utilisé une carte de taille 20*20. La figure 15 montre la carte de Kohonen qui porte l'information relative à la valeur de la fdp estimée. La figure 16 illustre le résultat de l'extraction des régions modales de la fdp qui sont représentés par des composantes connexes individualisées par la technique lpe. Les vecteurs poids dans l'espace IHS, relatifs aux régions modales sont considérées comme des prototypes des régions homogènes dans l'image (cf. figure 17), et sont ainsi à la base de l'assignation de tout pixel de l'image à l'un des domaines régionaux, moyennant la distance euclidienne sur la carte (cf. figure 18).



6. Conclusion

Dans ce travail, nous avons proposé une approche de classification automatique non supervisée des images couleurs, basée sur l'association d'un algorithme de la morphologie mathématique à une carte de Kohonen. Cette approche consiste en un premier temps à représenter la carte de Kohonen par la fdp sous jacente à l'échantillon d'observations représentatif des pixels d'une image dans l'espace 3D des composantes couleurs.

Les régions modales de cette fdp sont ensuite extraites en composantes connexes par la méthode de la ligne de partage des eaux où chaque composante correspond à une région homogène dans l'image. Enfin dans la phase de classification, les vecteurs poids correspondants aux régions modales ainsi extraites sont pris comme des prototypes des classes en présence dans l'image, et sont utilisés pour l'assignation de chaque pixel de l'image à l'une des classes identifiées. Cette approche montre, que dans un contexte non supervisé, des outils de la morphologie mathématique associés à la carte de Kohonen permettent une bonne classification automatique de l'image couleur sans passer par une quelconque procédure de seuillage. Les performances de cette approche ont été évaluées sur une image de synthèse. L'application sur une image réelle a donné des résultats satisfaisants surtout dans le cas où les observations présentent le cas enchevauché.

7. Références

- [1] T. Uchiyama et M.-A. Arbib. "Color image segmentation using competitive learning". *Pattern Analysis and Machine Intelligence*. Vol. 16, N 12, 1994.
- [2] A. Tremeau, P. Golantoni and B. Laget, "On colour segmentation guided by the cooccurrence matrix", *OSA Annual Conference on Optics and Imaging in the Information Age*, pp. 30-38, 1996.
- [3] A. Verikas, K. Malmqvist, L. Bergman, "Colour image segmentation by modular neural network", *Pattern Recognition Letters*, 1996.
- [4] P. Scheunders, "A Genetic C-Means Clustering Algorithm applied to Color Image Quantization", *Pattern Recognition*, Vol. 30, N6, pp. 859-866, 1997.
- [5] T. Géraud, P.-Y. Strub et J. Darbon, "Segmentation d'Images Couleur par Classification Morphologique non supervisée", *Proceeding of the International Conference on Image and Signal Processing ICISP'2001*, Agadir, Morocco, mai 2001.
- [6] T. Kohonen, "Self-Organisation and Associative Memory", *Springer-Verlag, 2nd Edition*, New York, 1984.
- [7] E. Claridge. "Shape Recognition using the Kohonen Self-Organising.Feature Map", *pattern recognition letters*. March 1992.
- [8] S. Delsert D. Hamad, M. Daoudi et J.-G. Postaire, "Competitive Learning Neural Networks Applied to Multivariate Data Set Reduction", *IEEE inter. Conf. On Systems, Man. And Cybernetics (SMC)*, Proceeding Vol. IV, pp. 496-500, le Touquet, France, October, 1993.
- [9] E. Parzen. "On Estimation of a probability density function and mode", *Ann. Math. Stat.*, Vol.33 pp. 1065-1076, 1962.
- [10] JP Asselin de Beauville, "l'estimation ds modes d'une densité de probabilité multidimensionnelle", *Revue statistique et Analyse des Données*, Vol. 8, No 7, pp 16-40, 1983.
- [11] JP Asselin de Beauville, "Panorama sur l'utilisation du mode en classification automatique". *RAIRO-APII*, 23, pp 113-137, 1989.
- [12] S. Beucher, "Extrema of Gray Tone Fonctions and Mathematical Morphology". *Rapport du C.G.M.M., Ecole des Mines, Fontainebleau*, n°793, 1983.
- [13] S. Beucher et C. Lantuejoul, "Use of Watersheds in Contour Detection". *Int. Workshop on Image Processing, CCETT/IRISA*, Rennes, 1979.
- [14] S. Beucher, "Segmentation Tools in Mathematical Morphology", *Image Algebra and Morphological Image Processing*, SPIE, Vol. 1350, pp. 70-84, 1990.
- [15] S. Kaski, "Data exploration Using Self-Organizing Maps", *Thesis for the degree of Doctor of technology*, Helsinki University of technology, March 1997.
- [16] J. Serra, "Image Analysis and Mathematical Morphology: Theoretical Advances", *Vol. 2, London*, 1988.
- [17] S.-R. Sternberg, "Grayscale Morphology". *Computer Vision, Graphics & Image Processing*, Vol. 35, pp. 335-355, 1986.
- [18] F. Meyer, "Skeletons and Perceptual Graphs", *Signal Processing*, Vol. 16, n° 4, pp. 335-363, 1989.