

SEGMENTATION D'IMAGES PAR UNE CARTE AUTO-ORGANISANTE DE KOHONEN

Slim M'HIRI Eric PETIT
Jacques LEMOINE Ahmed RAJI

L.E.R.I.S.S. Université Paris XII Val De Marne
e-mail : mhiri%leriss1@univ-paris12.fr

RÉSUMÉ

ABSTRACT

Dans cet article, nous présentons une méthode de segmentation d'images fondée sur l'approche neuronale des cartes auto-organisantes de Kohonen. La segmentation comprend une étape d'apprentissage suivie d'une classification. L'originalité de la méthode proposée réside dans la définition d'une stratégie d'apprentissage souple et efficace, permettant de pallier les inconvénients de la méthode classique tels que la convergence artificielle et l'absence d'un critère d'optimisation durant le processus d'apprentissage. De plus la méthode de classification que nous avons développée est non supervisée pour une carte donnée. Les résultats obtenus seront illustrés par un exemple d'image réelle du domaine biomédical.

In this paper, we present an image segmentation method layed on the property of Kohonen self-organizing feature maps. This method consist of a learning stage followed by a classification. Its originality resides in the definition of an efficient and adaptative learning strategy, allowing to palliate disadvantages of the classic method such as artificial convergence and absence of optimisation upon the learning stage. In addition this classification is non supervised for a given map. Results are illustrated on real image like biomédical images.

I. Introduction

I-1 : Cartes auto-organisantes de Kohonen

L'algorithme de Kohonen est un modèle d'apprentissage permettant de former, à partir d'un ensemble d'entrée quelconque, une cartographie de "propriétés" relative aux attributs des éléments d'entrée [KOH 90]. C'est un algorithme qui s'inspire de la capacité du cerveau à construire ce type de cartographies à partir de données sensorielles tactiles, visuelles ou acoustiques. Sans reproduire fidèlement le modèle du cerveau, l'algorithme de Kohonen en reprend le principe à l'aide de règles simples nécessitant un minimum de calcul.

Une propriété essentielle de ces cartes est la tonotopie. Selon les attributs considérés, des éléments d'entrée équivalents, en terme de ces attributs, se retrouvent codés sur la même cellule ou sur des cellules voisines de sortie.

L'algorithme de Kohonen décrit une phase d'apprentissage bien établi pour les cartes auto-organisantes et peut être implanté facilement [KOH 89]. L'algorithme décrit une projection d'un ensemble d'entrée \mathcal{E} à un espace de sortie \mathcal{S} . L'espace de sortie consiste en des noeuds j , qui sont arrangés dans un ordre topologique donné (sur une ligne ou sur une grille à deux dimensions). A chaque noeud de la couche de sortie est associé un vecteur poids.

I-2 : Apprentissage

La phase d'apprentissage correspond à une quantification vectorielle de l'image, elle définit une application entre l'ensemble des attributs extraits de l'image $\mathcal{E} \in \mathcal{R}^n$ et l'ensemble des cellules de la carte de Kohonen \mathcal{S} [BAI 89].



Soit $X \in \mathcal{E}$ un vecteur aléatoire avec une densité de probabilité $p(X)$. Soit $V = (V_1, V_2, \dots, V_c)$ l'ensemble des vecteurs réels attachés aux noeuds de la carte. Dans ce contexte le terme apprentissage consiste à trouver l'ensemble $\{V_j\}$ qui minimisent l'erreur [KOH 90] :

$$E = \iint_{\mathbb{R}^n} \dots \int \|X - V_1\|^2 p(X) dX$$

Lorsqu'un élément de l'ensemble d'entrée X est soumis au réseau, des distances sont calculé entre chaque les V_j et X . Le noeud de sortie qui donne la distance minimale est le noeud "Leader" dit V_1 .

La règle d'apprentissage consiste donc à faire évoluer la valeur du noeud "Leader" et ses voisins dans le temps suivant la règle :

$$\frac{dV_r}{dt} = \begin{cases} \alpha_t (X - V_r) & \text{si } r \in \text{Vois}_t(l) \\ 0 & \text{sinon} \end{cases}$$

le facteur d'apprentissage α_t , et le voisinage de mise à jour $\text{Vois}_t(l)$ doivent décroître avec le temps.

On montre [KOH 90] que l'algorithme converge, avec deux conditions sur le coefficient d'apprentissage α_t :

$$\begin{cases} \sum_{t=0}^{\infty} \alpha_t = \infty & (a) \\ \sum_{t=0}^{\infty} \alpha_t^2 < \infty & (b) \end{cases}$$

Ces conditions assurent que la réduction de α_t soit ni trop rapide ni trop lente. Comme l'a montré Grossberg [GRO 82], le système d'apprentissage doit être stable (b) pour se rappeler des anciennes forme apprises, et plastique (a) pour apprendre de nouvelles formes (dilemme stabilité-plasticité). En général α_t est pris sous la forme $\alpha_0 \left(1 - \frac{t}{T}\right)$ où T est le nombre maximal d'itérations.

La décroissance du facteur d'apprentissage force la convergence de l'algorithme en fixant un nombre limite d'itérations [BEZ 92], en effet

$\alpha_t \xrightarrow[t \rightarrow T]{} 0$. Ceci constitue une fin artificielle de l'algorithme. L'algorithme converge dans le sens où $V_t \xrightarrow[\alpha \rightarrow 0]{} V^*$. mais V^* est un point limite de la séquence itérative, ce n'est pas optimum par rapport à un modèle. En plus le facteur d'apprentissage α_t et le voisinage de mise à jour $\text{Vois}_t(l)$ doivent décroître avec le temps, le résultat final dépend du choix de ces deux paramètres et la façon avec laquelle on effectue cette décroissance.

Pour pallier ces deux problème nous proposons une nouvelle stratégie de mise à jour dans laquelle on minimise une fonctionnelle d'énergie qui mesure la dispersion locale autour du noeud leader.

II. Nouvelle stratégie de mise à jour :

On développe un nouvel algorithme dont la règle d'apprentissage dérive d'un problème d'optimisation. Soit $X = \{X\}$ l'ensemble des vecteurs d'entrée, ces vecteur sont distribué suivant la loi de probabilité $p(X)$ invariante dans le temps. Soit L_X , une fonction coût qui mesure l'erreur locale de X au noeud Leader V_1 .

posons :

$$\|X - V_1\|_- = \min_r \|X - V_r\| \text{ et } D = \sum_{j=1}^c f_1(j) \|X - V_j\|^2$$

$$L_X = L(X, V_1, \dots, V_c) = \frac{\|X - V_1\|_-^2}{D}$$

avec $f_1(r)$ une fonction décroissante, inversement proportionnelle à la distance topologique (sur la carte) entre les deux neurones l et r .

Notre objectif est de trouver un ensemble $V = \{V_r\}$, tel que L_X soit minimisé sur l'ensemble X . En d'autres termes on essaye de minimiser :

$$\Gamma(V) = \iint \dots \int_{\mathbb{R}^n} \frac{\|X - V_1\|_-^2}{D} p(X) dX$$

Pour un ensemble X fini de n vecteurs, le problème se réduit à une optimisation sans contrainte de :

$$\Gamma(V) = \sum_{k=1}^n \frac{\|X_k - V_1\|_-^2}{D} p_k$$



Comme dans la plupart des algorithmes d'apprentissage on approche le gradient de $\Gamma(\mathbf{V})$ par celui de la fonction L_X . En d'autres termes, on essaye de minimiser $\Gamma(\mathbf{V})$ par une recherche de "descente du gradient" locale utilisant les échantillons de la fonction L_X .

$$\frac{\partial L_X}{\partial V_1} = -2(X - V_1) \frac{D - f_1(l) \|X - V_1\|^2}{D^2}$$

$$\left. \frac{\partial L_X}{\partial V_r} \right|_{r \neq 1} = 2(X - V_r) \frac{f_1(r) \|X - V_1\|^2}{D^2}$$

on choisit donc comme nouvelle stratégie de mise à jour :

$$V_{r,t} = V_{r,t-1} + \alpha_t \cdot \beta_t(r,l) \cdot (X_t - V_{r,t-1})$$

$$\text{avec } \beta_t(r,l) = \begin{cases} \frac{D - f_1(l) \|X_m - V_1\|^2}{D^2} & \text{si } r = 1 \\ \frac{f_1(l) \|X_m - V_1\|^2}{D^2} & \text{sinon} \end{cases}$$

Avec cette nouvelle stratégie, il n'y a plus à choisir un voisinage de mise à jour. En effet toutes les cellules seront mise à jour à chaque présentation d'une nouvelle entrée au système.

D'après la règle ci-dessus on remarque qu'une réduction du coefficient d'apprentissage se fait automatiquement et adaptativement. Plus l'écart entre l'entrée et le noeud leader est grande, plus la mise à jour qui affecte les autres noeuds est importante. Plus cet écart est petit, plus on est près de la convergence donc plus la modification des noeuds autres que le leader est négligeable.

Le facteur $f_1(r)$ permet d'avoir une réduction du coefficient d'apprentissage en fonction de la distance (topologique sur la carte) du noeud leader.

III. Segmentation :

III-1 : Agrégation des noeuds

Dans cet article nous utilisons une carte monodimensionnelle. Dans ce cas il est plus approprié de parler d'une "chaîne" que d'une carte de Kohonen (fig.1). Dans toute la suite on prend le niveau de gris comme seul attribut.

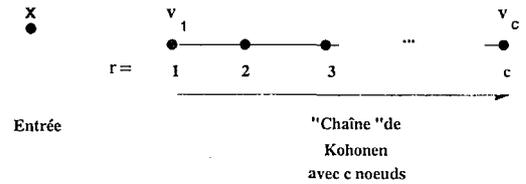


fig 1 : une chaîne de Kohonen de c cellules.

Les objectifs de l'algorithme de Kohonen diffèrent de celles des algorithmes de classification. L'objectif des cartes auto-organisantes est d'extraire et de relever les structures topologiques cachées dans les données. Or, lors d'une classification on cherche à trouver les centroïdes des classes.

Une propriété importante des cartes auto-organisantes est la Tonotopie, cette propriété assure que deux éléments de l'ensemble d'entrée se ressemblant seront codés sur la carte par deux cellules topologiquement voisines. Après la phase d'apprentissage, on peut utiliser cette propriété pour détecter les pixels susceptibles d'être des points de contours [MHI 94].

La Tonotopie assure aussi la formation d'amas autour des centres de classes. Nous avons donc développé une stratégie pour le regroupement de ces amas. Le nombre de ces amas nous donne le nombre de classes existant dans l'image. Chaque cellule sera donc un prototype de la classe à laquelle elle appartient :

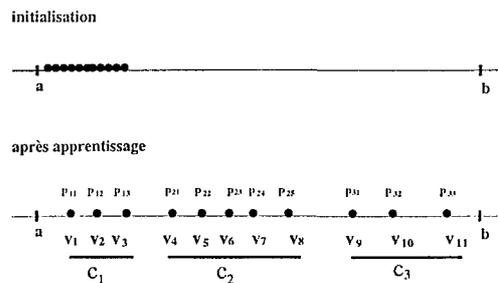


fig 2 : rassemblement des amas

p_{ij} est le prototype numéro j représentant la classe C_i .

III-2 : Classification

La phase de classification consiste donc à attribuer chaque pixel de l'image à la classe du prototype qui lui est le plus proche :

$$x \in C_i \text{ ssi } \arg \left[\min_j \left(\|x - p_{jk}\| \right) \right] = i$$



IV. Résultats :

Dans le cas d'images biomédicales tomographiques à rayons-X, souvent la répartition des niveaux de gris est caractéristique des objets qu'on cherche dans l'image. La figure (3.a) représente une image représentant une coupe tomographique de type Imatron. Sur cette image on cherche à détecter le contour ventriculaire endocardique. L'extraction de ce contour à une grande importance pour l'analyse quantitative de la fonction cardiaque particulièrement pour l'évaluation de la fonction ventriculaire gauche. La difficulté de la segmentation de ce type d'images est due à la micro texture couvrant toute la surface de l'image et à la lente transition entre les régions qui se confondent par certains endroits avec le bruit.

Nous avons appliqué notre algorithme sur cette image avec une chaîne de 10 cellules et en utilisant le niveau de gris comme seul attribut.

Après la phase d'apprentissage et une analyse de la chaîne, le système déduit le regroupement de cinq amas donc l'existence de cinq classes, la figure 3.b montre le résultat de la classification.

Si on utilise une carte de cinq cellules en supposant que chaque cellule représente une classe, on obtient le résultat de la figure 3.c. Cet exemple montre l'importance de l'agrégation des cellules. Sur la figure 3.d nous montrons le résultat de la segmentation avec 10 cellules sans regroupement d'amas (en supposant qu'il y ait 10 classes).



fig 3.a

fig 3.b

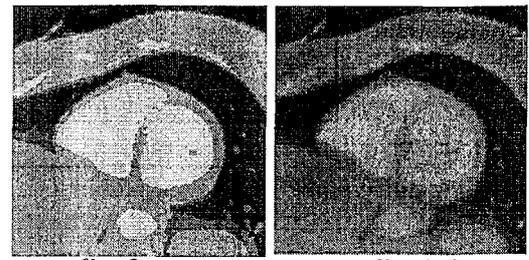


fig 3.c

fig 3.d

fig 3

V. Conclusion :

L'algorithme proposé est non supervisé, la phase d'apprentissage de cet algorithme découle d'un problème d'optimisation, lors de cette étape le voisinage de mise à jour est réglé adaptativement en fonction du degré de ressemblance de l'entrée du noeud leader. la deuxième phase de cet algorithme exploite la propriété de tonotopie de cartes auto-organisantes pour déduire le nombre de classes dans l'image et la classifier.

BIBLIOGRAPHIE :

[BAI 89] E. le Bail, A.Mitchie "Quantification vectorielle par le réseau neuronal de Kohonen", Traitement du Signal, Vol 6, n°6, 1989.

[BEZ 92] J.C.Bezdek, E.C. Tsao, N.R. Pal "Fuzzy Kohonen Clustering Networks", Proceedings of IEEE, int.conf Fuzzy Syst, Mar.1992, San Diego, CA, pp.1035.1041.

[GRO 82] S. Grossberg "Studies of Mind and Brain", Boston, MA : Reidel, 1982.

[KOH 89] T. Kohonen "Self-Organization and associative memory", Springer-Verlag, Berlin, 1989.

[KOH 90] T. Kohonen "The self-organizing map". Proceedings of IEEE, vol.78, No.9, sept.90.

[MHI 94] S.M'HIRI, S. DJEZIRI, E. PETIT, J. LEMOINE "Segmentation d'images fondée sur un modèle géométrique déformable", JTEA'94, 5-6-7 Nov 94, Tunisie, tome 1, pp.259-264.