

Réseaux complexes : Nouvelle approche pour la modélisation et la caractérisation de textures

Thomas CHALUMEAU¹, Luciano DA F. COSTA², Olivier LALIGANT¹, Fabrice MERIAUDEAU¹

¹Laboratoire Le2i - Université de Bourgogne
12 rue de la Fonderie, 71200 Le Creusot, France

²IFSC - Universidade de São Paulo
Caixa postal 369 - CEP:13560-970, São Carlos, Brasil

t.chalumeau@iutlecreusot.u-bourgogne.fr, luciano@ifsc.usp.br
o.laligant@iutlecreusot.u-bourgogne.fr, f.meriaudeau@iutlecreusot.u-bourgogne.fr

Résumé – Cet article décrit une nouvelle méthode et approche pour la caractérisation de texture. En utilisant une représentation des images en réseau complexe, les mesures classiques et dérivées (hiérarchiques), nous présentons comment obtenir de bons résultats en classification de texture. L'image est représenté par un réseau complexe : un pixel par un noeud. Les calculs des degrés d'un noeud et des coefficients de cluster, utilisés avec leurs mesures traditionnelles et étendues (hiérarchiques), sont utilisés pour caractériser "l'organisation" des textures.

Abstract – This article describes a new method and approach of texture characterization. Using complex network representation of an image, classical and derived (hierarchical) measurements, we present how to have good performance in texture classification. Image is represented by a complex networks : one pixel as a node. Node degree and clustering coefficient, using with traditional and extended hierarchical measurements, are used to characterize "organisation" of textures.

1 Introduction

L'analyse de texture joue un rôle important dans de nombreuses applications de traitement d'image. Diverses méthodes existent pour l'extraction de caractéristiques de textures, telles que les matrices de co-occurrence introduit par Haralick [1], les champs de Markov, les filtres de Gabor [2], le LBP [3]. Toutefois, l'analyse de texture est encore un sujet relativement ouvert pour lequel divers travaux de recherches sont régulièrement présentés. Notre approche est motivée par les récentes recherches faites sur les réseaux complexes. En effet, tel qu'ils sont présentés [4], les réseaux complexes et les outils de leur caractérisation semblent prometteur pour l'analyse des images. Un Réseau complexe est une représentation adaptée pour caractériser les relations et les interactions entre les différents éléments qui le composent [5]. L'objet de cet article est de présenter une méthode simple de représentation d'images par des réseaux complexes. Puis de montrer les outils permettant de caractériser les réseaux complexes et d'appliquer ceci à la caractérisation de texture.

Dans un premier temps, un rappel sur les réseaux complexes, leurs caractéristiques sera fait. Puis la méthode de conversion d'une image en réseau complexe sera développée. Les méthodes utilisées pour comparer nos résultats seront décrites. Les résultats des diverses méthodes seront exposés. Enfin, une conclusion et les perspectives termineront l'article.

2 Réseaux complexes et représentation de l'image

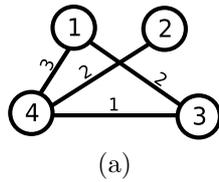
2.1 Réseaux complexes et mesures

Un réseau est une collection d'entités qui sont reliées ensemble. Un lien (connection) entre deux entités (noeuds) dénote une interaction entre ces deux entités. Ces connections peuvent être binaires (présence ou absence de connection) ou pondérées. Les réseaux complexes peuvent être représentés mathématiquement par une matrice appelée *matrice d'adjacence*. Pour un réseau complexe avec N noeuds, la matrice d'adjacence (W) a une dimension $N \times N$. Le poids des connections de chaque noeud j et chaque noeud i ($i, j = 1, 2, \dots, N$) est représenté par $W(i, j)$, avec une valeur nulle signifiant une absence de connection. Une seconde matrice W_t , binaire, est aussi définie. Elle contient seulement les connections les plus significatives. Par exemple, les connections ayant les poids les plus élevés (seulement les éléments de W qui sont plus grand ou égales à un seuil T sont gardées). Un exemple figure 1 peut être vu.

La caractérisation de la topologie et les propriétés des connections d'un réseau complexe peuvent être déterminées par des mesures issues de la théorie des graphes [6] et de la recherche sur les réseaux complexes [7], incluant, mais ne se limitant pas à :

2.1.1 Degré

Le degré d'un noeud est égale au nombre de connections qu'il possède. Dans le cas de connections pondérées,



0	0	2	3
0	0	0	2
2	0	0	1
3	2	1	0

(b)

0	0	1	1
0	0	0	1
1	0	0	0
1	1	0	0

(c)

FIG. 1 – (a) : Micro réseau complexe pondéré (b) : matrice d'adjacence W , (c) : matrice W_t (binaire) obtenue avec le seuil $T = 2$.

il correspond à la somme de tous les poids des connections respectives. Un exemple figure 2 permet d'illustrer. L'histogramme des fréquences des degrés donne une importante caractérisation de la connectivité du réseau.

2.1.2 Coefficient de cluster

Le coefficient de cluster pour un noeud est défini pour un noeud i par le nombre de connections entre les noeuds connectés à i divisé par le nombre de connections possibles entre ces mêmes noeuds. Lorsque le numérateur ou le dénominateur de ce quotient sont nuls, le coefficient de cluster est nul. On peut noter que la valeur est comprise entre 0 et 1 pour n'importe quel noeud. Un exemple est donné figure 2.

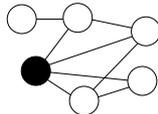


FIG. 2 – Illustration du calcul du degré et du coefficient de cluster pour le noeud représenté en noir : $D = 4$ et $C = \frac{3}{4 \times 3 \sqrt{2}} = \frac{1}{2}$.

2.1.3 Mesures hiérarchiques

Certaines mesures de réseaux complexes, incluant le degré et le coefficient de cluster, peuvent être généralisées pour tenir compte non pas seulement des voisins immédiats mais également des voisins à plusieurs distances pour un noeud spécifique, comme l'illustre l'exemple figure 3. En particulier, le degré hiérarchique d'un noeud à une distance correspond au nombre de liens connectés les noeuds à la distance i à la distance $i + 1$. De même pour le coefficient de cluster.

Pour toutes ces mesures, tous les noeuds du réseau complexe sont caractérisés. Pour avoir une information globale du réseau, la moyenne et l'écart type sont déterminés à partir de l'histogramme de fréquence obtenu pour chaque mesure.

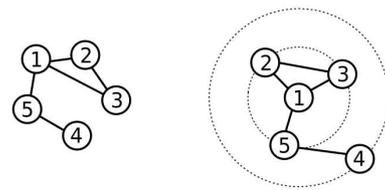


FIG. 3 – Représentation hiérarchique ou multi-échelle (à gauche) du réseau complexe original (à droite).

2.2 Représentation d'une image

Pour transformer une image d'une dimension $M \times M$ en réseau complexe, nous définissons que chaque pixel est représenté par un noeud. Pour chaque noeud, on définit les connections avec les noeuds voisins (noeuds dont la distance euclidienne par rapport au noeud courant est inférieure à un rayon fixé) comme ayant un poids égale à la valeur absolue de la différence de niveau de gris entre les pixels. On obtient alors une matrice adjacente W , de dimension $N \times N$ avec $N = M^2$. Dans ce cas là, une connection ayant un poids faible définit une connection très forte, et une grande valeur signifie une connection pauvre. Un exemple de construction des matrices W et W_t est illustré Figure 4 et une représentation en réseau complexe d'une image Figure 5.

10	12	28
16	25	31

(a)

x	2	18	6	15	21
2	x	16	4	13	19
18	16	x	12	3	3
6	4	12	x	9	15
15	13	3	9	x	6
21	19	3	15	6	x

(b)

0	1	0	1	0	0
1	0	0	1	0	0
0	0	0	0	1	1
1	1	0	0	0	0
0	0	1	0	0	1
0	0	1	0	1	0

(c)

FIG. 4 – (a) : partie d'une image en niveau de gris (b) : matrice d'adjacence (W) de l'imagette, (c) : matrice W_t avec un seuil $T = 8$.

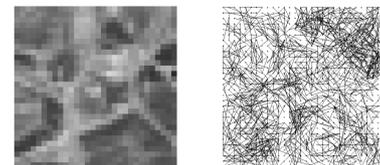


FIG. 5 – Image de dimension 30×30 et sa représentation graphique en réseau complexe.

3 Méthodes comparatives

Les résultats obtenus utilisant la méthode utilisant les réseaux complexes a été comparée avec la méthode des

matrices de co-occurrence introduite par Haralick [8] et les filtres de Gabor [9, 2].

3.1 Les matrices de co-occurrence :

Les matrices de co-occurrence considèrent les répétition d'apparition de plusieurs niveaux de gris .

Les matrices de co-occurrence considèrent des occurrences répétées d'une certaine configuration de niveau gris dans la texture. Une matrice de co-occurrence est construite en observant des paires de pixels séparés par une distance d et incrémente la position de matrice correspondante au niveau gris des deux pixels. La valeur $p(i, j)$ représente la fréquence de l'occurrence de la situation $f(x1, y1) = i, f(x2, y2) = j, |x1 - x2| = d$.

Diverses caractéristiques peuvent être extraites à partir de la matrice de co-occurrence : énergie, contraste, corrélation, dissimilitude, homogénéité. Dans notre cas, ces caractéristiques ont été déterminées avec $d = 1$ et $d = 5$ [10].

3.2 Les filtres de Gabor :

Les filtres de Gabor, utilisant une analyse de Fourier sont essentiellement sinus et cosinus (exponentiel complexe) modulés par une fenêtre gaussienne. En espace complexe ces filtres sont exprimés comme :

$$h(x, y) = g(x', y').e^{j2\pi(Ux + Vy)} \quad (1)$$

$$\text{où } g(x, y) = \frac{1}{2\pi\lambda\sigma} .e^{-\frac{(x/\lambda)^2 + y^2}{2\sigma^2}}$$

$$\text{et } \begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} x.\cos(\phi) + y.\sin(\phi) \\ -x.\sin(\phi) + y.\cos(\phi) \end{bmatrix}$$

ϕ est une rotation dans le sens des aiguilles d'une montre le long de l'axe de x , U et V représentent les coordonnées de fréquence.

σ est l'écart type de l'enveloppe gaussienne (qui définit sa taille) et α est le paramètre de forme de la gaussienne.

La gaussienne a une forme circulaire pour $\alpha = 1$.

La fonction de transfert de $h(x, y)$ est exprimé comme :

$$H(x, y) = G(u' - U', v' - U') \quad (2)$$

$$\text{avec } G(u, v) = e^{-2\pi^2\sigma^2(u^2\lambda^2 + v^2)}$$

$$\text{et } \begin{bmatrix} u' \\ v' \end{bmatrix} = \begin{bmatrix} u.\cos(\phi) + v.\sin(\phi) \\ -u.\sin(\phi) + v.\cos(\phi) \end{bmatrix}$$

$H(u, v)$ est donc un filtre passe-bande gaussien, dont l'axe principal est orienté au degré de ϕ de l'axe de u . La fréquence centrale F est défini par : $F = (U + V)^{1/2}$, orientée selon l'angle polaire θ , comme décrit dans la Figure 6. Dans notre cas, 3 fréquences et 6 angles sont employés, avec $\phi = \text{deta}$. Le paramètre extrait des résultats est l'énergie :

$$\text{Energie} = \sum \text{pixel}^2; \quad (3)$$

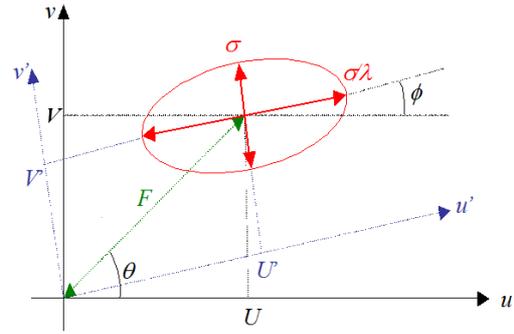


FIG. 6 – : Représentation d'un filtre de Gabor dans l'espace de Fourier avec $\theta \neq \phi$.

4 Résultats

L'étude comparative a été réalisée tout en considérant différentes textures résultant de la base de donnée CU-ReT¹. Six différentes textures, illustrées Figure 7, ont été utilisées. Pour toutes les textures, 20 "imassettes" sont considérées.

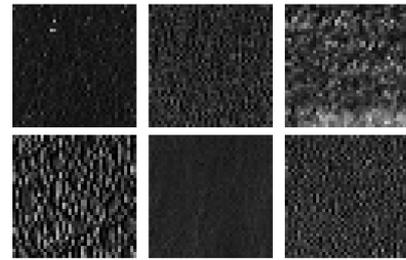


FIG. 7 – Exemple des 6 textures utilisées.

Deux différents essais de classification ont été effectués. Le premier est un perceptron multicouche du logiciel TANAGRA [11], le second, un classificateur bayésien. Le perceptron multicouche a 25 neurones, avec 500 itérations maximum et un taux d'apprentissage égale à 0.25.

Le classificateur bayésien est basé sur le modèle normal de probabilité [12], dont l'équation est donnée par :

$$p(\vec{x}) = \alpha \exp \left\{ -\frac{1}{2} (\vec{x} - \vec{\mu}_{\vec{X}})^T K^{-1} (\vec{x} - \vec{\mu}_{\vec{X}}) \right\} \quad (4)$$

$$\text{avec } \alpha = \frac{1}{(2\pi)^{N/2} \sqrt{\text{Det}\{K\}}}$$

où \vec{x} est un vecteur aléatoire, $\vec{\mu}_{\vec{X}}$ correspond au vecteur moyen, et K est la matrice de covariance.

Les deux méthodes emploient 50% des "imassettes" pour l'apprentissage et 50% pour la classification. Pour comparer nos résultats de classification aux méthodes comparatives, le taux d'erreur est défini comme le nombre de mauvaises classifications divisé par le nombre d'échantillons.

¹http://www1.cs.columbia.edu/CAVE/software/curet/

4.1 Méthode classique :

La Table 1 montre le taux d'erreur de classification pour notre méthode (avec des seuils différents), et pour la comparaison, avec les résultats obtenus en utilisant la méthode des matrices de co-occurrence et les filtres de Gabor.

TAB. 1 – Taux d'erreur (T.E.) des deux classifications (perceptron et méthode bayésienne) pour la méthode utilisant les réseaux complexes et les mesures simples, l'approche d'Haralick et les filtres de Gabor.

Méthode	distance	seuil	T. E. percep.	T.E. Baye
Graphe	5	2	0.19	0.10
Graphe	5	5	0.12	0.13
Haralick	1	/	0.23	0.17
Haralick	5	/	0.26	0.17
Gabor	/	/	0.23	0.17

4.2 Méthode hiérarchique :

Le taux d'erreur est également déterminé avec tous les différents niveaux hiérarchiques. L'évolution de ce taux d'erreur prend en considération successivement les différents niveaux hiérarchiques (abscisses), comme on peut le voir Figure 8. Il faut ajouter que la valeur sur l'axe des abscisses indique l'utilisation de tous les niveaux hiérarchiques jusqu'au niveau k , et non pas seulement le niveau k .

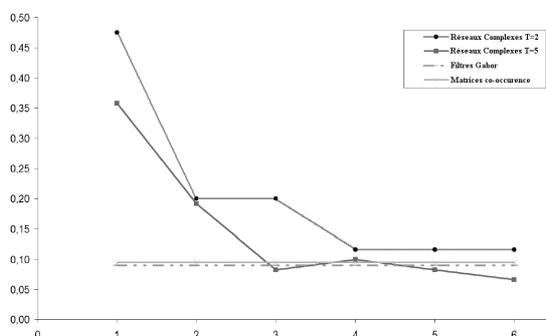


FIG. 8 – Evolution du taux d'erreur en fonction des niveaux hiérarchiques utilisés. Ces résultats ont été obtenus à l'aide du perceptron.

Avec ces résultats, il s'avère que l'utilisation des mesures considérant les niveaux hiérarchiques a un effet positif en améliorant le taux de classification (taux d'erreur inférieur). Le minimum du taux d'erreur n'est pas obtenu pour les niveaux hiérarchiques les plus élevés utilisés (3 et 4). Ce meilleur niveau hiérarchique dépend de la taille d'image, la région circulaire, de la définition des connexions et du seuil. Si le niveau hiérarchique est trop élevé, les raccordements entre les noeuds sont pauvres (ou inexistants), et les paramètres déterminés (degré et coefficient de cluster) ne peuvent pas être adaptés pour discriminer des réseaux.

5 Conclusion

Deux méthodes pour la classification de texture employant les réseaux complexes ont été présentées et comparées. Notre méthode simple, en utilisant les réseaux complexes avec des mesures de topologie et de connectivité, a une bonne capacité de représenter et de caractériser les textures. L'intérêt des niveaux hiérarchiques a été mis en avant par l'augmentation de l'efficacité de la classification. Des résultats encourageants ont été obtenus en utilisant des paramètres de simples. Nous travaillons actuellement pour améliorer les faiblesses de la méthode : avoir plus d'information sur les histogrammes déterminer (utilisation des moments et des coefficients), avoir une détermination automatique du meilleur niveau hiérarchique et du meilleur seuil.

Références

- [1] J. Haddon and J. Boyce, "Co-occurrence matrices for image analysis," *Electronics & Communication Engineering Journal* **5** (2), pp. 71–83, 1993.
- [2] P. Kruizinga, N. Petkov, and S. Grigorescu, "Comparison of texture features based on gabor filters," *Proceeding of the 10th International Conference on Image Analysis and Processing*, pp. pp. 142–147, 1999.
- [3] G. Zhao and M. Pietikainen, "Local binary pattern descriptors for dynamic texture recognition," *Pattern Recognition* **2**, pp. 211 – 214, 2006.
- [4] L. da Fontoura Costa, "Complex networks, simple vision," *cond-mat/0403346*, 2004.
- [5] M. E. J. Newman, "The structure and function of complex networks," *cond-mat/0303516*, 2003.
- [6] R. Diestel, *Graph Theory*, Springer, 2nd electronic edition ed., 2000.
- [7] R. Albert and A.-L. Barabasi, "Statistical mechanics of complex networks," *cond-mat/0106096*, 2001.
- [8] L.-K. Soh and C. Tsatsoulis, "Texture analysis of sar sea ice imagery using gray level co-occurrence matrices," *IEEE Transactions on geoscience and remote sensing* **37**(2), pp. 780–795, 1999.
- [9] C. Palm and T. M. Lehmann, "Classification of color textures by gabor filtering," *Machine GRAPHICS & VISION* Vol. **11**, p. pp 195 – 219, 2002.
- [10] N. Pican, E. Trucco, M. Ross, D. M. Lane, Y. Pettillot, and I. Ruiz, "Texture analysis for seabed classification : Co-occurrence matrices vs self-organizingmaps.," *IEEE/OES OCEANS '98 Conference Proceedings* **1**, pp. 424–428, 1998.
- [11] R. Rakotomalala, "Tanagra : un logiciel gratuit pour l'enseignement et la recherche," in *Actes de EGC'2005, RNTI-E-3* **2**, pp. 697–702, 2005.
- [12] L. da Fontoura Costa and R. M. C. Junior, *Shape Analysis and Classification : Theory and Practice*, CRC Press, Inc, 2000.