# Identification sans contrainte de stationnarité d'un modèle AR d'une texture

#### Bertrand AUGEREAU, Majdi KHOUDEIR, Jacky BERNARD

Laboratoire Signal Image et Communications de l'Université de Poitiers IRCOM-SIC, UMR 6615
Bâtiment SP2MI, Bvd 3 - Téléport 2, BP 179
86960 Futuroscope Cedex

RÉSUMÉ ABSTRACT

Un problème classique en analyse d'image est d'obtenir une modélisation caractéristique d'images texturées. L'utilisation d'un modèle AR-2D fournit souvent des solutions efficaces. Cependant, l'identification des cœfficients d'un tel modèle est assujettie à l'hypothèse de stationnarité du signal. Pour résoudre ce problème, nous considérons la distribution spatiale du signal générateur utilisé avec le modèle AR-2D. L'originalité de ce travail vient d'une identification simultanée des paramètres du modèle et des échantillons du générateur, ceci par un processus neuronal. Ainsi, comme résultats nouveaux, nous proposons une méthode permettant de représenter une texture par un couple d'attributs, un modèle AR-2D et une distribution spatiale du signal générateur.

## 1 Introduction

Une image texturée X correspond à un modèle AR-2D [1] [2] si pour tout pixel (i, j) le niveau de gris  $x_{i,j}$  vérifie la relation

$$x_{i,j} = b_{i,j} + \sum_{k,l} a_{k,l} x_{i-k,j-l}$$
 (1).

Les  $b_{i,j}$  sont les niveaux de gris du signal générateur, couramment une image bruit  $\mathbf{B}$ . Les  $a_{k,l}$  sont les cœfficients du modèle, voir  $figure\ l$ , le couple (k,l) appartenant à  $[0..N] \times [0..N] - (0,0)$ , N étant l'ordre du modèle.

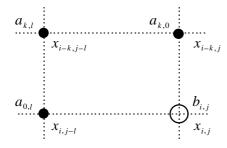


figure 1 : le modèle AR-2D

Estimating a representative model for textured images is a well-known problem in image analysis. One of the effective solutions is the use of a 2D-AR model. However, the identification of the model coefficients often fails because of the stationary signal hypothesis. We use the spatial distribution of the input signal for textures defined by a 2D-AR model in order to deal with this problem. The originality of the work rest on a simultaneous identification of parameters of the texture model and of spatial sampling of the input signal, according to a neural process. So, as new results, we propose a method that allows us to represent a texture by a couple of attributes, a 2D-AR model and a spatial distribution of the input signal.

Pour identifier les  $a_{k,l}$ , on utilise habituellement les fonctions d'autocorrélations de l'image. L'efficacité de la méthode est extrêmement liée au choix de la fenêtre d'identification. En effet, en ne faisant appel qu'aux propriétés statistiques d'un bruit générateur, on s'impose implicitement une hypothèse de stationnarité. Pour remédier à ces inconvénients, il faut tenir compte de la répartition spatiale du signal générateur. C'est l'objet de la méthode d'identification présentée.

# 2 Identification par apprentissage réparti

## 2.1 Le modèle AR-2D neuronal

Soit X l'image texturée dont on cherche un modèle AR-2D. On suppose donc qu'elle peut être produite à l'aide de cœfficients  $\mathbf{W} = \left(w_{k,l}\right)$  et d'un signal générateur  $\mathbf{R} = \left(r_{i,j}\right)$ . Pour un pixel (i,j), la relation (1) se traduit en

$$E_{i,j} = r_{i,j} + \sum_{k,l} w_{k,l} \ x_{i-k,j-l}$$
 (2)

où nous pouvons interpréter  $E_{i,j}$  comme l'entrée totale d'un neurone [3] , figure~2. Ce neurone possède

 $(N+1)^2$  entrées réparties en deux catégories. Tout d'abord,  $(N+1)^2-1$  entrées reçoivent les vecteurs  $\mathbf{x}_{i,j} = \left(x_{i-k,j-l}\right)_{k,l}$ , les poids  $w_{k,l}$  associés à ces connexions représentent les cœfficients du modèle. Enfin, l'entrée restante est induite par le signal générateur.

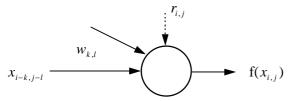


figure 2 : le modèle AR-2D neuronal

# 2.2 Apprentissage réparti

Pour identifier, nous effectuons un apprentissage supervisé avec comme échantillon un ensemble de couples  $((\mathbf{x}_{i,j}, r_{i,j}), f(x_{i,j}))$  où f est la fonction de

transfert du neurone, une sigmoïde 
$$f(t) = \frac{1}{1 + \exp(-t)}$$
.

Initialement, les poids et le signal générateur sont nuls. A chaque étape de l'apprentissage, nous procédons à une phase de propagation de l'ensemble de l'échantillon. On calcule alors les modifications des poids

$$\Delta w_{k,l} = -\frac{\partial C}{\partial w_{k,l}} \tag{3}$$

le critère C à optimiser étant l'erreur globale  $C = \sum_{i,j} C_{i,j}$  avec  $C_{i,j} = (f(E_{i,j}) - f(x_{i,j}))^2$ .

Parallèlement, on calcule

$$\Delta r_{i,j} = -\frac{\partial C_{i,j}}{\partial r_{i,j}} \tag{4}$$

les modifications du signal générateur.

La seconde phase, celle de rétropropagation des erreurs, utilise deux pas du gradient  $\lambda_w$  et  $\lambda_R$  calculés tous deux selon par un algorithme BP- $\lambda$ L. Ces deux pas du gradient

$$\lambda_{\mathbf{W}} = \left| \sum_{k,l} \frac{\partial^{2} C}{\partial w_{k,l}^{2}} \right|^{-1} \text{et } \lambda_{\mathbf{R}} = \left| \sum_{i,j} \frac{\partial^{2} C}{\partial r_{i,j}^{2}} \right|^{-1}$$
 (5)

assurent la stabilité du processus d'apprentissage [4]. D'un point de vue global, le signal générateur est donc une entrée associée à un poids fixe unitaire pour l'actualisation des poids. Mais c'est également, pour sa propre actualisation, un biais local. Les actualisations à la nième étape sont pour les poids

$$w_{k,l}^{n+1} = w_{k,l}^{n} + \lambda_{\mathbf{W}} \Delta w_{k,l}^{n}$$
 (6)

et pour le générateur

$$r_{i,j}^{n+1} = r_{i,j}^n + \lambda_{\mathbf{R}} \Delta r_{i,j}^n \tag{7}$$

En définissant ainsi l'apprentissage, il procède selon des modes respectivement différés et instantanés. C'est ce que nous appelons donc l'apprentissage réparti.

# 2.3 Propriétés de la méthode d'identification

Cette identification par apprentissage réparti recherche simultanément pour la modélisation d'une texture AR-2D un couple composé, d'une part, d'un modèle défini par les cœfficients, et d'autre part, d'un signal générateur caractérisé spatialement. Cette méthode particulière ne comporte aucune hypothèse quant à la répartition de l'information. Cela fait, entre autre, que le choix de la fenêtre d'identification, l'échantillon d'apprentissage, n'est plus soumis qu'à la seule contrainte de sa représentativité vis-à-vis de la texture.

# 3 Résultats expérimentaux

#### 3.1 Identification et non-stationnarité

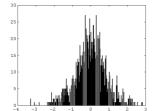
Tout d'abord, nous illustrons l'indépendance de l'identification face à l'hypothèse de stationnarité. Pour cela nous générons une image texturée  $256 \times 256$  avec pour signal générateur un bruit gaussien de distribution normale et comme cœfficients du modèle AR-2D

$$\mathbf{A} = \begin{bmatrix} 0 & 0.1 \\ 0.6 & 0.2 \end{bmatrix}$$
. Ensuite, cette image est l'objet d'une

identification à partir d'une fenêtre  $40 \times 40$  située à l'origine de la génération. Le signal générateur original restreint à cette fenêtre,  $\mathbf{B}_f$ , est de moyenne -0.008 et d'écart type 0.8241, son histogramme est présenté *figure* 

3.a. L'identification par apprentissage réparti donne des cœfficients  $\mathbf{W} = \begin{bmatrix} 0 & 0.0836 \\ 0.5900 & 0.2190 \end{bmatrix}$ . La similitude des

cœfficients montre bien que la non stationnarité a été reportée sur le signal générateur identifié **R**, de moyenne -0.019 et d'écart type 0.8215, son histogramme étant donné *figure 3.b*.



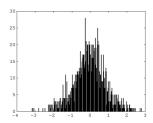
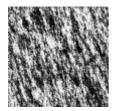


figure 3.a et 3.b : histogrammes de  $\mathbf{B}_f$  et  $\mathbf{R}$ 

Pour juger de la qualité des résultats obtenus, nous effectuons une synthèse comparative. Avec un signal générateur gaussien appliqué soit au modèle **A**, soit au modèle **W**, on obtient respectivement les images des *figures 4.a* et *4.b*. La distance moyenne entre ces deux images est de 1.54, le calcul se faisant avec des niveaux de gris variant de 0 à 255.



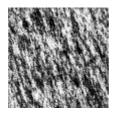


figure 4.a et 4.b : images générée avec A et W

# 3.2 Identification du couple modèle-générateur

Dans ce deuxième exemple, nous allons mettre en avant l'intérêt de l'association modèle et générateur. Pour cela, nous nous plaçons dans une situation où les modèles AR-2D sont réputés inapplicables. En effet nous considérons un générateur déterministe représenté figure 5.a. Avec ce signal et un modèle de cœfficients

$$\begin{bmatrix} 0 & 0.35 \\ 0.35 & 0.25 \end{bmatrix}$$
, nous générons l'image de la *figure 5.b*.





figure 5.a et 5.b : signal générateur et texture obtenue

Sur cette image, prise dans sa totalité, une identification par les fonctions d'autocorrélations donne les cœfficients  $\begin{bmatrix} 0 & 0.9963 \\ 0.9963 & -0.9935 \end{bmatrix}. \quad \text{Par} \quad \text{contre},$ 

l'identification par apprentissage réparti fournit le jeu de cœfficients  $\begin{bmatrix} 0 & 0.3717 \\ 0.3717 & 0.2807 \end{bmatrix}$  associé au générateur de la *figure 6*.



figure 6 : signal générateur identifié

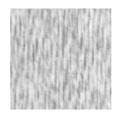
On doit constater que le bon résultat, obtenu dans cet exemple, est bien dû à la prise en compte de la répartition spatiale du signal générateur lors de l'identification.

# 3.3 Images réelles

Les deux derniers résultats présentés sont des identifications faites sur des images de référence. Ici, nous utilisons une fenêtre  $50 \times 50$  et l'ordre des modèles est fixé à 4. Tout d'abord nous considérons une texture "eau", *figure 7*, fournie par le GDR-ISIS et tirée du Brodatz [5]. Les images de la *figure 8* sont des exemples de synthèses faites après identification par notre méthode. Pour tirer parti de l'information fournie par le générateur identifié, nous utilisons en synthèse des signaux construits à partir des moments calculés sur le signal identifié.



figure 7 : image de référence "eau"



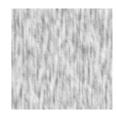


figure 8 : exemples de synthèses

Enfin, nous utilisons une partie texturée de l'image "fissures", *figure 9*. Après identification et synthèse, nous obtenons les images de la *figure 10*.

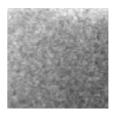
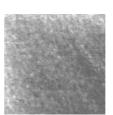


figure 9 : image de référence "fissures"



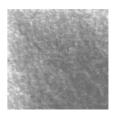


figure 10 : exemples de synthèses

## 4 Conclusion

La méthode d'identification par apprentissage réparti se propose de rechercher simultanément les cœfficients du modèle AR-2D et la définition spatiale du signal générateur. Cette démarche permet tout d'abord de s'affranchir des contraintes d'une stationnarité habituellement supposée. De plus, la méthode proposée permet de représenter une texture par un couple d'attributs : un modèle AR-2D et une répartition du signal générateur. Cet apport d'informations permet d'enrichir notablement le champ d'application des modèles AR-2D.

## 5 Références

- [1] H. Mhidra, J. Brochard, M. Leard "AR models and bidimensional discrete moments applied to texture modelling and recognition" Pattern recognition, vol 25 n° 5, p. 721-726, 1993.
- [2] H. Iversen, T. Lonnestad "An evaluation of stochastic models for analysis and synthesis of grayscale texture" Pattern recognition letters, vol 15 n° 6, p. 575-585, 1994.
- [3] L. Sukissian, S. Kollias, Y. Boutalis "Adaptative classification of textured images during linear prediction and neural networks" Signal processing, vol 36 n° 2, p. 209-232, 1994.
- [4] B. Augereau, T. Simon, J. Bernard, B. Heit "The BP-λL algorithm: non-chaotic and accelerated learning in a MLP network" Lectures notes in computer science IWANN'95, volume 930, p 231-239, Springer-Verlag, 1995.
- [5] P. Brodatz "Textures: a photographic album for artists and designers" Dover Publications, 1966.