

Détection de contour par la méthode de filtrage paramétrique

Yacine AIT ALI YAHIA, Abderazek GUESSOUM

INSTITUT NATIONAL D'INFORMATIQUE

INI BP 68M OUED-SMAR 16270, Alger, ALGERIA

y_ait_yahia@ini.dz

aguessoum@caramail.com

Résumé: La détection de contours n'est pas un objectif en soi, elle est la première étape dans un système de vision, pour cela des variétés de détecteurs de contours ont été proposées, ils diffèrent dans leurs propriétés mathématiques et algorithmiques, et le type de contours qu'ils sont capables d'extraire. On propose une nouvelle méthode de détection de contours, qui s'appelle filtrage paramétrique, elle ouvre de nouvelles très prometteuses dans l'analyse de contour et la segmentation, incluant en particulier, le signal d'autocorrélation de premier ordre $g_q(h)$ l'analyse de la corrélation temporelle et la mesure de distorsion basée sur le signal $g_q(h)$.

Mots clés: Détection de contour, filtrage paramétrique, mesure de distorsion, structure d'autocorrélation.

1 Introduction

La détection de contours n'est pas une fin en soi, elle est la première étape dans un système de vision. En effet, un détecteur de contours fournit en résultat un ensemble de points. Ceux-ci regroupés pour former des chaînes de points de contours qui peuvent être considérées comme une représentation intermédiaire [20],[21]. Les nouvelles techniques de traitements du signal digital pour détecter les contours d'images sont considérables[22],[23]. L'une de ses approches est appelée filtrage paramétrique [2], [3].

Cette méthode est appliquée avec succès sur la parole et la segmentation vocale [8], [9], on va la projeter par application sur la détection du contour. Cette nouvelle approche ouvre des voies très prometteuses dans l'analyse de contour et la segmentation, la méthode proposée combine un filtre paramétrique avec l'analyse de l'autocorrélation du premier ordre du signal image filtré, ceci fait il produira une nouvelle fonction caractéristique pour le spectre de signal image, se basant sur cette nouvelle fonction caractéristique, divers mesures de distorsion sont proposées comme des indicateurs du changement spectral. Ces indicateurs présentent de bonnes performances pour la détection de contour et pour la segmentation.

2 Vue générale sur la méthode de Filtrage Paramétrique

2.1 Les méthodes à modèle

Elles dépendent essentiellement des modélisations LPC. Une des méthodes est dérivée d'un test GLR (a generalized likelihood ratio) en supposant que le signal entrant est une partie d'un processus autorégressif conduite par le bruit blanc Gaussien. En donnant un domaine du signal, la méthode, en principe, teste l'hypothèse qu'aucun changement ne se produit dans le domaine alors qu'une variation a lieu dans ce domaine à un certain temps t . Utilisant les modèles LPC, les fonctions de probabilités Gaussienne (Gaussien likelihood functions) sont évaluées sous les deux hypothèses et le rapport de vraisemblance (the likelihood ratio) D_t est calculé pour chaque t . Si D_t est maximisé en $t=t^*$ et le maximum excède un certain seuil, un changement en $t=t^*$ est apparu [3], [12], [16].

En plus, les rapports de vraisemblance des modèles LPC sont aussi employés comme estimateurs spectraux (Spectral estimators) dans le calcul des mesures de distorsion pour détecter les variations spectrales.

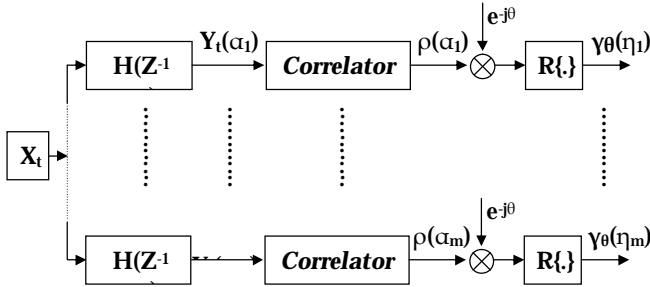


Figure.1. Schéma bloc de filtrage paramétrique

2.2 Les méthodes sans modèles

Les méthodes sans modèles existantes sont généralement basées sur l'utilisation directe du spectre de l'image, couplée avec une mesure de distorsion spectrale. Par exemple Deshayes et Picard utilisent la distance spectrale de Kolmogorov-Smirnov :

$$D = \sup |F_1(w) - F_2(w)|$$

et la distance spectrale de

$$\text{Cramer-Von Mises} : D = \int |F_1(w) - F_2(w)|^2 dw$$

ou $F_1(w)$ et $F_2(w)$ sont des fonctions de distributions spectrales estimées des deux domaines du signal pris dans le voisinage du temps t. La variation est déclarée comme avoir lieu en t si la distance calculée en t excède un seuil.

D'autres distances spectrales (mesures de distorsions) peuvent être aussi bien employées pour ces buts, deux exemples sont la divergence spectrale de Kullback-Leibler (KL)

$$D_{KL} = \int_{-p}^p K \left[\frac{f_1(w)}{f_2(w)} \right] dw \tag{1}$$

Avec $K(u) = u - \log(u) - 1$

Et la distance L_2 de log-spectrum :

$$D_{LL2} = \int |\log f_1(w) - \log f_2(w)|^2 dw \tag{2}$$

Ou $f_1(w)$ et $f_2(w)$ sont des fonctions de densité spectrale estimées de deux domaines du signal au voisinage de t [12], [14].

3. La méthode de filtrage paramétrique

La méthode de filtrage paramétrique (FP) est motivée par le fait que la structure de corrélation d'un signal stationnaire peut être caractérisé par la signature de certaines sorties statistiques d'un filtre judicieusement désigné

3.1 La méthode de base

Supposons $\{X_t\}$ est un signal stationnaire à valeurs réels avec la moyenne égale à zéro et une fonction d'autocorrélation égale à :

$$r_k = E(X_{t+k} X_t) / E(X_t^2) \tag{3}$$

Considérons le filtre récursive IIR $H(z^{-1}; a)$ définie par :

$$Y_t(a) = \sum_{l=0}^{\infty} \bar{a}^l X_{t-l} = \bar{a} Y_{t-1}(a) + X_t \tag{4}$$

ou : $a = he^{-jq}$ est un nombre complexe avec $|h| < 1$ et $q \in [-p, p]$ et \bar{a} représente le conjugué de a . Soit $r(a)$ l'autocorrélation d'ordre un de $\{Y_t(a)\}$

$$r(a) = \frac{E(Y_{t+1}(a) \cdot \bar{Y}_t(a))}{E(|Y_t(a)|^2)} \tag{5}$$

Pour tout J fixé, on définit l'autocorrélation de premier ordre démodulée du signal $\{Y_t(a)\}$ comme suit : $g_q(h) = \Re(e^{-jq} r(a))$ (6)

Ou : $\Re(\cdot)$ représente la partie réelle d'un nombre

Complexe. Dans cet article, on utilise $g_q(h)$ comme une nouvelle fonction caractéristique, complémentaire au spectre de Fourier pour la représentation de la structure de corrélation de $\{X_t\}$. Nous appellerons cette méthode d'analyse des structures d'autocorrélation la méthode de filtrage paramétrique.

Pour calculer $g_q(h)$, nous n'allons imposer aucun modèle paramétrique ou des suppositions de distributions sur $\{X_t\}$; c'est pour ça que cette méthode appartient à la catégorie des méthodes sans modèles sans utiliser explicitement les densités spectrales. Dans l'application, cette

méthode peut être implémentée facilement avec un filtre paramétrique de paramètre a comme le montre la figure N°1, ou les h_k peuvent être pris par exemple, uniformément dans l'intervalle $[h_a, h_b] \subset]-1, 1[$. Pour chaque évaluation de $g_q(h)$, le nombre de multiplications exigé est proportionnelle à la longueur du signal appliqué, et habituellement, quelques évaluations suffisent pour les besoins de la détection de contour proposée.

3.2 Mesures de distorsion

Etant donné deux domaines (ou plages) du signal image à traiter, nommés $X_t^{(1)}$ et $X_t^{(2)}$, la propriété caractéristique de $g_q(h)$ peut être utilisée pour dériver des mesures de distorsion qui quantifient les déviations de $X_t^{(1)}$ et $X_t^{(2)}$ dans leurs structures de corrélation. Pour la segmentation d'images, $X_t^{(1)}$ et $X_t^{(2)}$ peuvent être pris comme des segments donnés sous forme de pixels de différentes intensités (niveau de gris), ainsi de grandes valeurs de distorsion indiquent la présence significatif de changements dans la structure de corrélation.

La méthode de filtrage paramétrique appliquée à la détection de contour d'une image est basée sur des mesures de distorsion [12],[13],[16] qui incluent la distance L_p de $g_q(h)$, c'est à dire:

$$g_{\Omega}^p = \left(\int_{\Omega} |g_q^{(1)}(h) - g_q^{(2)}(h)|^p dq dh \right)^{1/p} \quad (7)$$

Pour $p \in (0, \infty)$, et la distance KL définie par

$$\hat{K}_{\Omega} = \int_{\Omega} \left(K \left[\frac{p_q^{(1)}(h)}{p_q^{(2)}(h)} \right] + K \left[\frac{p_q^{(2)}(h)}{p_q^{(1)}(h)} \right] \right) dq dh \quad (8)$$

Ou

$$\hat{K}_{\Omega} = \int_{\Omega} \left(p_q^{(2)}(h) K \left[\frac{p_q^{(1)}(h)}{p_q^{(2)}(h)} \right] + p_q^{(1)}(h) K \left[\frac{p_q^{(2)}(h)}{p_q^{(1)}(h)} \right] \right) dq dh$$

Dans cette expression Ω est un sous ensemble

$] -p, p] \times [h_a, h_b]$, $g_q^{(1)}(\cdot)$ et $g_q^{(2)}(\cdot)$ sont les fonction caractéristique obtenue de $X_t^{(1)}$ et $X_t^{(2)}$

respectivement .

$p_q^{(1)}(\cdot)$ et $p_q^{(2)}(\cdot)$ sont les fonctions densités définie dans l'intervalle $[h_a, h_b] \subset]-1, 1[$ ayant la forme

$$p_q(h) = \frac{1}{2} \left(\frac{dg_q(h)}{dh} + [g_q(h_a) + 1]d(h - h_a) + [1 - g_q(h_b)]d(h - h_b) \right)$$

Dans l'application ces mesures de distorsion sont discrétiser en utilisant la sortie $g_q(h)$ du filtre de la figure 1[16],[17],[19].

4. Application à la détection de contour

4.1. Les points maximal dans la détection de contour

Dans notre expérience préliminaire de la détection de contour de l'image, l'approche de choix du pic est employée pour la détection [3],[14],[15]. Une méthode typique de choix du pic prend des portes (ou des fenêtres) de **2N-Points** du signal image original, en chaque point 't'; une fenêtre (porte) est centrée en 't' et l'autre et décalée avant de **m-points**.

Pour la suite de toutes les expériences, on prend **m=N/2** (i.e. 50% de *chevauchement*). Les deux portes sont multipliées par la *fenêtre de Hamming* de Points (*Hamming Window*) avant de les utiliser dans l'évaluation des mesures de distorsions. Soit D_t le résultat de distorsions; les localisations de changement spectrales. Ces localisation peuvent être identifiés par le passage par zéro (*the zero crossing*) de la différence $D_t - D_{t-1}$. Un pic de D_t est considéré comme significatif si son amplitude dépasse un seuil T [3][14].

Une performance améliorée peut être obtenue en général par le lissage (*smoothing*) de la trajectoire de D_t avant le pas de choix du pic [3].

4.2 L'implémentation de logiciel :

La démarche suivie pour l'implémentation de logiciel de la méthode PF pour la détection de contour est illustrée dans la figure N°2

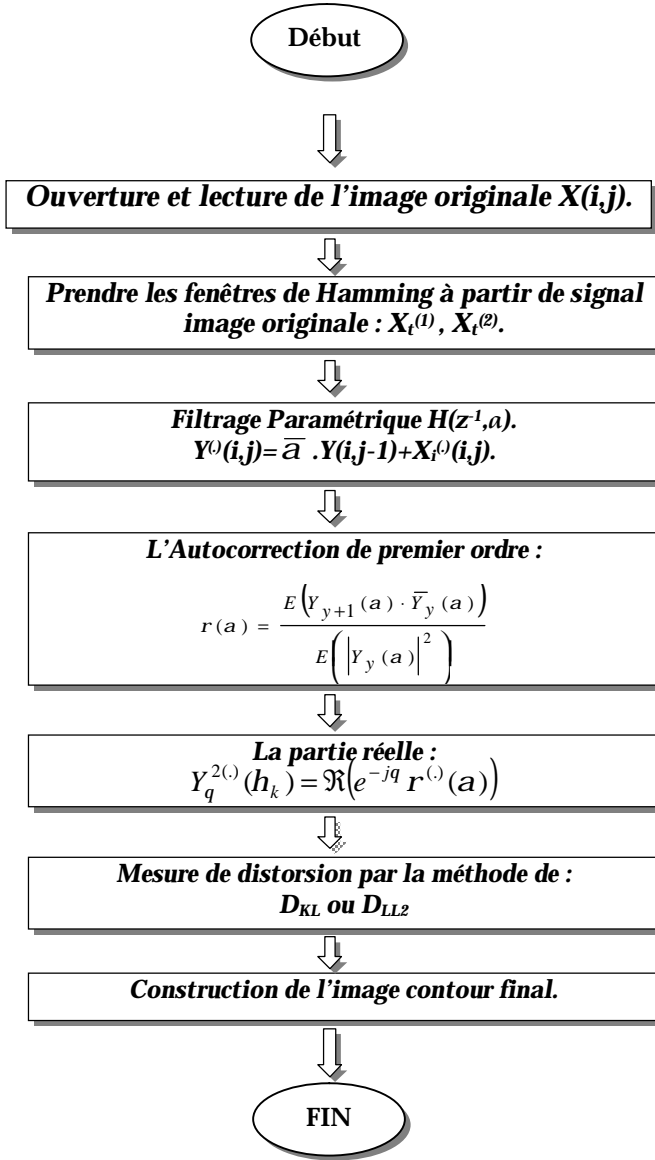


Figure 2 : L'organigramme de détection de contour par la méthode FP.

4.3. La Méthode FP en Bidimensionnel :

On applique cette technique (méthode PF) sur une image I(x,y), donc, on va suivre ces étapes :

1) On va calculer le paramètre α : $\alpha_k = h_k e^{jq}$ avec:

$$h_k = h_a + \frac{(k-1)(h_b - h_a)}{(m-1)}, \text{ pour } k=1, \dots, m.$$

2) On filtre l'image I(x,y) suivant les lignes (X) :

$$Y_x^{(i)} = \alpha \cdot Y_{x-1}^{(i)} + X_x^{(i)}$$

3) L'autocorrélation suivant les lignes (X) :

$$r(a) = \frac{E(Y_{x+1}(a) \cdot \bar{Y}_x(a))}{E(|Y_x(a)|^2)}$$

Et ensuite, on prend : $Y_q^{2(i)}(h_k) = \Re(e^{-jq} r^{(i)}(a))$

4) On fixe θ , N et m pour mesurer la distorsion par :

- La méthode $D_{k,L}$ suivant les lignes (X):

$$\hat{K}_{q,x} = \sqrt{N} \cdot \frac{1}{m+1} \sum_{k=0}^m \left(K \left[\frac{p_{q,x,k}^{(1)}}{p_{q,x,k}^{(2)}} \right] + K \left[\frac{p_{q,x,k}^{(2)}}{p_{q,x,k}^{(1)}} \right] \right)$$

Où : $p_{q,x,k}^{(i)} = g_{q,x}^{(i)}(h_1) + 1$, pour : $k=0$.

Et : $p_{q,x,m}^{(i)} = 1 - g_{q,x}^{(i)}(h_m)$, pour $k=m$.

Et : $p_{q,x,k}^{(i)} = g_{q,x}^{(i)}(h_{k+1}) - g_{q,x}^{(i)}(h_k)$, pour $k=1, \dots, m-1$.

- La méthode $D_{L,L-2}$ suivant les lignes(X) :

$$g_{q,x}^2 = \sqrt{N} \frac{1}{m} \sum_{k=1}^m |g_{q,x}^{(1)}(h_k) - g_{q,x}^{(2)}(h_k)|^2$$

Avec : $g_{q,x}^{(1)}(h_k)$, $g_{q,x}^{(2)}(h_k)$, sont les deux signaux filtrés.

5) On filtre l'image I(x,y) suivant les colonnes(Y) :

$$Y_y^{(i)} = \alpha \cdot Y_{y-1}^{(i)} + X_y^{(i)}$$

6) L'Autocorrection suivant les colonnes(Y) :

$$r(a) = \frac{E(Y_{y+1}(a) \cdot \bar{Y}_y(a))}{E(|Y_y(a)|^2)}$$

Et ensuite, on prend : $Y_q^{2(i)}(h_k) = \Re(e^{-jq} r^{(i)}(a))$

7) On fixe θ , N et m pour mesurer la distorsion par :

- La méthode $D_{k,L}$ suivant les colonnes(Y) :

$$\hat{K}_{q,y} = \sqrt{N} \cdot \frac{1}{m+1} \sum_{k=0}^m \left(K \left[\frac{p_{q,y,k}^{(1)}}{p_{q,y,k}^{(2)}} \right] + K \left[\frac{p_{q,y,k}^{(2)}}{p_{q,y,k}^{(1)}} \right] \right)$$

Où : $p_{q,y,k}^{(c)} = g_{q,y}^{(c)}(h_1) + 1$, pour : $k=0$.

Et : $p_{q,y,m}^{(c)} = 1 - g_{q,y}^{(c)}(h_m)$, pour : $k=m$.

Et : $p_{q,y,k}^{(c)} = g_{q,y}^{(c)}(h_{k+1}) - g_{q,y}^{(c)}(h_k)$, pour : $k=1, \dots, m-1$.

- La méthode D1.1.2 suivant les colonnes (Y) :

$$g_{q,y}^2 = \sqrt{N} \frac{1}{m} \sum_{k=1}^m \left| g_{q,y}^{(1)}(h_k) - g_{q,y}^{(2)}(h_k) \right|^2$$

Avec : $g_{q,y}^{(1)}(h_k), g_{q,y}^{(2)}(h_k)$ sont les deux signaux filtres.

8) Finalement, on calcule la moyenne des deux mesures de distorsions suivant X et Y :

- La méthode D_{KL} :

$$\hat{K}_q = (\hat{K}_{q,x} + \hat{K}_{q,y}) / 2.$$

- La méthode D1.1.2 :

$$g_q^2 = \sqrt{|g_{q,x}^2| + |g_{q,y}^2|}$$

On obtient les maximums suivants (X) et (Y) de l'image pour avoir le contour voulu.

5. Résultats pratiques :

En s'inspirant des travaux réalisés par Ta-Hsin sur la segmentation audio [16] et en tenant compte de nos travaux expérimentaux nous montrons ici quelque uns des résultats obtenus. La figure 3 représente une image de dimension 256x256 codée en 256 niveaux de gris, représentant différents objets sur laquelle on test l'algorithme de filtrage paramétrique.

En ce que concerne la taille des fenêtres Hamming, nos testes sont effectués sur des fenêtres de taille $N=4$.

La figure 4 montre l'image contour quand la mesure de distorsion D_{KL} est utilisée avec les paramètres suivant : $h_a = 0.0, h_b = 0.9, f = 0.00063p, m = 2$.

La figure 5 montre l'image contour quand la mesure

de distorsion D_{LL2} est utilisée avec les paramètres suivant :

$h_a = -0.5, h_b = 0.5, f = 0.05p, m = 2$.



Figure 3 : image originale d'objets




Figure 4 : image contour avec la méthode D_{KL}




Figure 5 : image contour avec la méthode D_{LL2}

6. Conclusion Générale :

Dans cet article, une nouvelle méthode de détection de contour d'image et de caractérisation de l'image est présentée. La méthode PF emploie un filtre judicieusement déterminé, qui préserve la structure de corrélation du signal en entrée dans l'autocorrélation $g_o(h)$ de la sortie. Ceci amène au tracé du 'TCA' montrant aussi bien l'évolution temporelle de la structure de corrélation de l'image que diverses mesures de distorsion qui quantifient la déviation entre deux zones du signal (*Les deux signaux de hamming*) pour la détection de contour d'une image.

Les recherches futures incluent l'expérimentation d'autres mesures de distorsion aux différents changements spectraux et la sélection des paramètres adéquats pour la détection de contours.

References

- [1] J.R. Deller, Jr., J. Proakis, and J. H. L. Hansen, *Discrete-Time processing of Speech signals*. New York: Macmillan, 1993.
- [2] R. Adre-Obrech, *A new statistical approaches for automatic segmentation of continuous speech signals*, IEEE Trans. Acoust., Speech, Signal Processing, vol 36, pp 29-40, Jan 1998.
- [3] E. Vidal and A. Marzal, *A review and new approach for automatic segmentation of speech signals*, in Signal Processing V: *Theories and Application*, L. Torres et al. Eds. New York: Elsevier, 1990, vol 1 pp. 43-53.
- [4] L. Rabiner and B.H. Juang, *Fundamental of speech Recognition*. Englewood Cliffs, NJ: Prentice-Hall, 1993
- [5] L. R. Rabiner, J.G Wilpon, and F. K. Soong, *high performance connected digit. Recognition using hidden Markov models*. IEEE Trans. Acoust., Speech, Signal Processing, vol. 37, pp 1214-1225, Aug 1989.
- [6] E. Paksoy, K. Sanivasan, and A. Gersho, *Variable rate speech coding with phonetic segmentation*, in Proc. ICASSP, Minneapolis, MN, Apr.1993, vol. 2, pp 155-158.
- [7] S. Wang and A. Gersho, *Improved phonetically-segmentation vector excitation coding at 3.4 kb/s*, in Proc. ICASSP San Francisco, CA, Mar 1992, vol. 1, pp.349-352.
- [8] T.H. Li and J.D. Gibson, *Discrimination of time series of, speech by parametric filtering*, J. Amer. Stat. Assoc, vol. 91, pp. 284-296, Mar. 1996.
- [9] T.H. Li and J.D. Gibson, *Discrimination analysis of speech by parametric filtering*, in Proc. IEEE conf Inform. Science, Systems, Princeton, NJ, Mar. 1994, pp. 575-580.
- [10] M. Basseville and A. Benvenise, *Detection of Abrupt Changes in Signals and Dynamical System*. New York. Springer, 1986.
- [11] M. Basseville and I.V. Nikoiforov, *Detection of Abrupt Changes*, Theory and Application. Englewood Cliffs, NJ Prentice-Hall 1993.
- [12] M. Basseville, *Distance measures for signal processing and pattern recognition*, Signal Processing, vol. 18, pp. 349-369, 1989.
- [13] R.M. Gray, A. Bazo, Y. Matsuyama, *Distortion measures for Speech processing*, IEEE Trans. Acoust, Speech, Signal Processing, vol ASSP-28, pp. 367-376, Apr. 1980.
- [14] T. Svendsen and F.K. Soong, *On the automatic segmentation of speech signals*, in Proc. ICASSP. Dallas, TX, Apr. 1987, P 77-80.
- [15] J.G. Wilpon, B.H. Juang, and L.R. Rabiner, *An investigation on the use of acoustic sub-word units for automatic speech recognition*, in Proc. ICASSP, TX, Apr.1987, pp 821-824.
- [16] S.M. Kay, *Modern Spectral Estimation*, Theory and Application. Englewood Cliffs NJ, Prentice-Hall, 1988.
- [17] M. Lavielle, *Detection of changes in the spectrum of a multidimensional process*, IEE Trans. Signal processing, vol. 41, pp. 742-749 Feb. 1993.
- [18] E. Parzen, *Times series, statistics, and information*, in New Directions in Time Series Analysis, P1. 1, D Brillinger, Eds New York: Springer-Verlag, 1992, pp 265-286.
- [19] T.H. Li and J.D. Gibson, *Speech Analysis and Segmentation by parametric filtering* IEEE Trans on speech and audio processing. Vol.4, No 3 May 1996 pp 203-213.
- [20] I.J. Cox, R. A Boie and D.A. Wallach, *Line recognition*, IEEE Proceedings of the 10th International Conference on Pattern Recognition, Atlantic City (New Jersey), Vol.2, P639-645, 1990.
- [21] Gonzalez R, Woods R. *Digital image Processing*, Addison Wesley, Reading, Mass. 1992.
- [22] D.Marr, H. Hildreth, *Theory of Edj Detection* Proceedings of the Royal Society of London B207, P 187-217, 1980.
- [23] H.D. Tagare, R.J.P de Figueiredo *On delocalization performance measure and optimal edge detection*, IEEE Transactions on Pattern analysis and machine intelligence, Vol.12 N°12, December 1990.