

Quantification de la perfusion hépatique dans les images échographiques de contraste

A. KISSI³, S. CORMIER², F. TRANQUART¹

¹INSERM Unité 619, CHRU Bretonneau, 2 boulevard Tonnelé 37044 Tours Cedex

³ERIM INSERM ERI 14, 28 place Henri Dunant, BP38, 63001 Clermont Ferrand Cedex

²LERI/CRESTIC, Université de Champagne-Ardenne, 2 rue de la Crayères, BP 1035, Reims Cedex

cormier@univ-reims.fr

Résumé – Cet article présente une nouvelle technique de quantification automatique de la perfusion hépatique dans les images échographiques de contraste. Elle exploite les caractéristiques des séquences pour construire une nouvelle méthode de diffusion anisotrope robuste permettant de s'affranchir des problèmes de seuillage et d'obtenir un traitement qui s'adapte en tout point à l'information contenue dans l'image. Cette approche est ensuite couplée avec une classification floue non exclusive pour segmenter les lésions.

Abstract – This article deals with liver lesions segmentation in ultrasound nonlinear imaging sequences. The method is divided into two stages. Initially, we developed an anisotropic diffusion step which raised the structural characteristics to eliminate the speckle. Then, a fuzzy competitive clustering process allowed us to delineate liver lesions. This method has been used to detect focal hepatic lesions. Our results show that this method improves markedly the recognition of focal hepatic lesions and opens the way for future precise quantification of contrast enhancement.

1. Introduction

L'échographie de contraste est une nouvelle technique d'imagerie médicale permettant de visualiser en temps réel la vascularisation. Son principe repose sur l'injection de microbulles, qui vont se comporter comme des traceurs intravasculaires, permettant ainsi de rehausser l'information ultrasonore, de détecter et caractériser la néovascularisation associée à la genèse de lésions hépatiques focales. L'évaluation de la perfusion est cependant qualitative, très dépendante de l'expérience du praticien et dans le cas de pathologies diffuses ne permet pas d'établir un diagnostic avec certitude. Dans ce contexte, nous proposons une méthode de quantification automatique de la perfusion basée sur une segmentation spatio-temporelle de lésions hépatiques focales qui exploite les caractéristiques anatomiques et fonctionnelles des séquences. Tout d'abord, une étape de régularisation par diffusion anisotrope basée sur une estimation robuste de l'anisotropie locale des tissus est réalisée. Cette méthode permet de s'affranchir des contraintes d'acquisition et d'obtenir des entités régulières, consistantes facilitant la quantification. La segmentation finale s'obtient ensuite à partir d'images filtrées par une approche de classification floue non exclusive afin d'y extraire une courbe décrivant l'activité fonctionnelle du produit de contraste autorisant ainsi la surveillance et l'adaptation de la posologie pour des traitements anti-

angiogéniques. Nous avons testé avec succès notre méthode sur un jeu de données de deux séquences d'images ultrasonores de contraste représentant diverses conditions de diffusion et de densités de diffuseurs.

2. Régularisation par diffusion anisotrope

2.1 Le principe de la diffusion anisotrope

Les images échographiques de contraste sont particulièrement difficiles à analyser car elles présentent les caractéristiques anatomiques et fonctionnelles dans un contexte très bruité. Une étape de régularisation est alors nécessaire pour réduire le bruit de speckle, considéré comme Rayleigh distribué dans notre étude.

La régularisation nécessite tout d'abord de calculer le tenseur de structure lissé $J_\rho = K_\rho * J$ où K_ρ est un noyau gaussien 2D de variance σ et J une matrice 2x2 symétrique définie positive telle que $J = (\nabla I \nabla^T)$. Ce tenseur fournit une information liée à la structure locale de l'image : ses vecteurs propres e_1, e_2 donnent les orientations locales et ses valeurs propres λ_1, λ_2 les variations de contraste le long de ces orientations. Les valeurs propres caractérisent le type de structure puisque leur différence est liée à l'anisotropie locale des tissus. Ainsi, une région corrompue par du bruit de speckle est caractérisée par une

faible anisotropie des tissus alors qu'une zone très structurée par une forte anisotropie. Il est alors possible de définir le comportement local du lissage désiré à l'aide du tenseur de diffusion D tel que :

$$D = c_1(\lambda_1, \lambda_2) e_1 e_1^T + c_2(\lambda_1, \lambda_2) e_2 e_2^T$$

Où c_1 et c_2 sont les fonctions qui permettent de diffuser fortement dans les zones à faibles gradients (zones homogènes) et faiblement dans les zones de forts gradients (les contours) dans les directions e_1 et e_2 . Elles sont contrôlées par un paramètre d'échelle μ tel que si $|\lambda_1 - \lambda_2| \ll \mu$, le filtre est gaussien sinon passe tout. Ainsi, le processus de régularisation consiste à adapter la diffusion en fonction de l'anisotropie mesurée en faisant évoluer l'équation aux dérivées partielles suivante :

$$\frac{\partial I}{\partial t} = \text{div}(D \nabla I)$$

Cette approche est cependant limitée par l'utilisation du seuillage des valeurs propres du tenseur. La diffusion n'étant jamais réellement nulle aux contours, tous les contours même les plus importants sont diffusés. Nous proposons une nouvelle fonction de diffusion pour lever cette limitation.

2.2 Le coefficient de diffusion

Black et *al.* ont établi une relation entre le processus de diffusion anisotrope et les statistiques robuste [1]. La régularisation d'une image par le processus de diffusion anisotrope revient à estimer une image constante par morceaux à partir d'une image bruitée. Nous proposons donc de définir une fonction de diffusivité qui intègre les statistiques locales de l'image afin de s'affranchir des problèmes de seuillage et d'obtenir un traitement qui s'adapte en tout point à l'information contenue dans l'image. Ces fonctions combinent une distribution de Rayleigh modélisant les régions constantes corrompues par le bruit de speckle avec une t-distribution correspondant aux contours, telles que :

$$c_i = (1 - w_i) \frac{x}{\sigma} \exp\left(-\frac{x^2}{\sigma^2}\right) + w_i \left(1 + \frac{x^2}{\sigma^2}\right)^{-t}$$

Avec $i = \{1, 2\}$, w_i un terme de mélange tel que $0 < w_i < 1$, t le degré de la t-distribution et σ un paramètre d'échelle lié au bruit commun aux deux diffusivités. Les fonctions de diffusion sont déterminées à partir d'une estimation de la log-vraisemblance de l'histogramme normalisé des valeurs propres, caractérisant la distribution des gradients de l'image [2].

L'équation de diffusion est alors résolue en utilisant les différences finies telles que :

$$\frac{I^{l+1} - I^l}{\tau} = \nabla(D \nabla I^l) \Leftrightarrow I^{l+1} = (1 + \tau A^l) I^l$$

Avec l le pas d'itération du processus et A^l une matrice 3×3 de différenciation représentant la discrétisation de $\nabla(D \nabla)$ composée d'opérateurs dérivatifs de premier ordre séparable qui optimisent l'invariance rotationnelle afin d'estimer l'anisotropie des tissus sans biais.

3. La classification floue non exclusive

La segmentation finale est obtenue à partir de l'image filtrée par classification. L'information pertinente est le niveau de gris correspondant à un niveau de vascularisation. La segmentation consiste alors à regrouper, de manière automatique, l'ensemble des pixels en C classes, de sorte que les groupes obtenus contiennent des pixels ayant des comportements hémodynamiques les plus semblables possibles. Un pixel n'appartient pas de manière exclusive à une classe car la frontière entre le tissu et la lésion n'est pas abrupte. Il peut donc présenter des similitudes avec des éléments d'autres classes, si bien que son appartenance peut être distribuée sur plusieurs classes. Le concept d'ensembles flous permet alors de représenter ces données imprécises de façon compacte et intuitive. La segmentation par classification non exclusive a pour but de générer une partition floue en minimisant la fonctionnelle J suivante [3] :

$$J = \sum_{i=1}^C \sum_{j=1}^N (u_{ij})^2 (d_{ij})^2 - \alpha \sum_{i=1}^C \left[\sum_{j=1}^N u_{ij} \right]^2$$

Avec :

- C le nombre de classes mis à jour de façon dynamique au cours des itérations ($1 \leq C \leq N$)
- N le nombre de pixels dans l'image.
- $U = [u_{ik}]$ de degré d'appartenance de chaque pixel i à la classe k
- α un paramètre facilitant le regroupement.

L'affectation d'un élément à une classe s'effectue à l'aide d'une phase de décision en intégrant un critère spatial décrivant le contexte, c'est à dire le voisinage dans lequel sont situés les points en deux temps. Une première phase consiste à comparer les degrés d'appartenance à un seuil fixé ε . Soit $m_i = \max_{k=1 \dots C} (u_{ik})$, le maximum des degrés d'appartenance pour un individu k . Si $m_i \geq \varepsilon$, l'individu est affecté à la classe k . Sinon, il est considéré comme ambigu. Une phase d'exploration spatiale permet d'affecter ce pixel à la classe majoritaire parmi ses voisins [4], [5].

4. Résultats

Nous présentons dans cette partie les résultats de notre méthode appliquée sur des données issues de l'hôpital Bretonneau de Tours composées de trois séquences de 71

images de résolution 576x768 obtenues avec un échographe Siemens Acuson 512 et une sonde 4C1, en mode CPS, après injection de produit de contraste Sonovue.




FIG. 1 : Résultats du filtrage avec respectivement (a) l'image originale, (b) l'image régularisée avec une diffusion Perona et Malik, (c) le résultat de notre méthode de filtrage

TAB. 1 : Statistiques des résultats de chaque filtre

	MSE	Entropie	Variance
Image originale	-	11.9636	0.0623
Perona et Malik	8.5e-09	11.8009	0.0283
Notre approche	0.0019	14.0124	0.0207

La figure 1 présente les résultats de notre méthode de régularisation avec $\sigma=3$, $t=10.15$, $\omega=0.17$ pour c_1 et, $t=4.97$, $\omega=0.57$ pour c_2 et le filtrage de Perona et Malik ($\lambda=0.1$). La qualité de notre lissage est ensuite évaluée et comparée au filtre de Perona et Malik en calculant trois paramètres statistiques : l'entropie, la variance et l'erreur quadratique moyenne (MSE) qui mesurent respectivement l'homogénéité des régions, la préservation des contours et la différence entre l'image originale et l'image lissée. Les valeurs de ces différents paramètres sont données dans le tableau 1. Les résultats montrent que notre filtre a la meilleure entropie et la plus faible variance. C'est donc celui qui préserve le mieux les contours et a la meilleure précision.

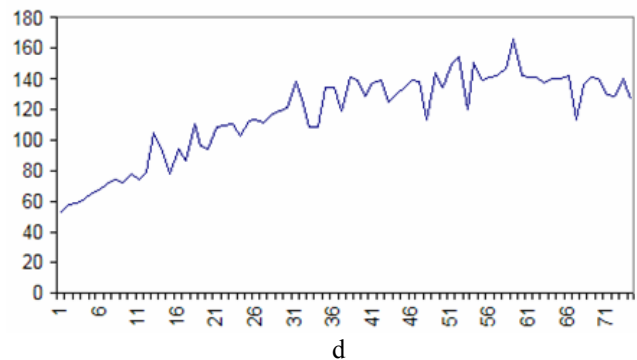



FIG. 2 : Résultats obtenus à partir de la méthode de classification non exclusive sur une métastase hypervasculaire sur des images prises à 8s (a), 25s(b) et 39s (c) après l'injection et (d) la courbe de perfusion correspondant obtenue, en calculant la perfusion moyenne dans la zone segmentée.

A l'issue de notre segmentation, nous obtenons une partition de l'image en deux classes représentant respectivement la lésion et le tissu environnant. La courbe perfusion, présentée à la figure 2d, est obtenue en calculant l'intensité moyenne de niveau de gris dans la région segmentée correspondant à la tumeur. L'activité fonctionnelle dans les images est telle que [6] :

$$SI(t) = SI_{\max} (1 - e^{-\beta t})$$

Avec β et SI_{\max} respectivement la cinétique de perfusion et le signal maximum dans la région segmentée au pic de perfusion. La qualité de la segmentation est ensuite évaluée en calculant le pourcentage de pixels mal classés par rapport à celle de notre expert médical. Nous obtenons une erreur de segmentation de 6%.

Références

- [1] M. Black et S. Guillermo. *Robust anisotropic diffusion*. IEEE Trans. on Image Processing, 1998, 7(3) p. 214-432.
- [2] H. Schar, M. Black et H. Haussecker. *Image statistics and anisotropic diffusion*. IEEE ICCV, 2003, p. 804-847.
- [3] R. Krishnapuram et H. Frigui, *A Robust Competitive Clustering Algorithm with Applications in Computer Vision*, IEEE Trans. on P.A.M.I., 21(5), p. 450-465.
- [4] N. Boujemaa et G. Stamon, *fuzzy modelling in early vision- Application to medical image segmentation*. In Progress in Image Analysis and Processing III. S. Impedovo-World Scientifique, 1994, p. 649-656.
- [5] A. Kissi, S. Cormier, L. Pourcelot, F. Tranquart, *Automatic lesions segmentation in ultrasound nonlinear imaging», IEEE Conference on Image Processing, ICIP'05, Gênes, Italie, 1153-1157*
- [6] K. Wei *et al.* (1998), *Quantification of myocardial blood flow with ultrasound-induced destruction of microbubbles administered as a constant venous infusion*, Circulation 97(5): 473-83