

# Analyse automatique des images de "flicker" en optique adaptative pour l'étude du couplage neuro-vasculaire

Abir AISSA<sup>1</sup> Florence ROSSANT<sup>1</sup> H el ene URIEN<sup>1</sup> Daniela CASTRO FAR IAS<sup>2</sup> Michel PAQUES<sup>2</sup>

<sup>1</sup>ISEP, Laboratoire d'Informatique, Signal et Image,  lectronique et T el ecommunications, 10 rue de Vanves, 92130 Issy-les-Moulineaux, France

<sup>2</sup>CIC 1423, H opital des Quinze-Vingts, 28 rue de Charenton, 75012 Paris, France

**R esum e** – Nous pr esentons nos travaux sur la segmentation et l'analyse de la qualit e des images en optique adaptative, appliqu es aux s eries d'images de flicker. Nous proposons une approche de pr ediction de la qualit e bas ee sur l'apprentissage profond. Ainsi, la segmentation pr ealable de l'image de meilleure qualit e permet d'am eliorer la segmentation des autres images de la s erie, et finalement d'obtenir des mesures pr ecises, avec pour seule intervention de l'expert la s election de la zone d'int er et.

**Abstract** – We present our work on the segmentation and quality assessment of adaptive optics images, applied to flicker image sequences. We propose a quality prediction approach based on deep learning. By first segmenting the highest-quality frame, our method enhances segmentation across the entire sequence, enabling precise and robust measurements. Expert input is limited to selecting the region of interest, thus streamlining the analysis of flicker series.

## 1 Introduction

L'imagerie r etiniennne par optique adaptative (OA) permet de visualiser le r eseau vasculaire de la r etine humaine avec une r esolution proche du micron, et ainsi d' tudier pr ecis ement les alt erations vasculaires r esultant de pathologies, ophtalmologiques ou non. Des  tudes cliniques ont ainsi mis en  vidence des modifications morphologiques dans les cas de diab etes [7], d'hypertension art erielle [6] ou de maladies affectant les petits vaisseaux c erebraux [8]. En particulier, le wall to lumen ratio ( $wlr$ ), d efini comme le rapport entre l' paisseur de la paroi art erielle et le diam etre de la lumi ere (voir Section 3.2), est un biomarqueur robuste qui peut  valuer le degr e de tonus vasculaire. Il a  t e d emontr e que les patients hypertendus pr esentent un  $wlr$  plus important que la normale [6].

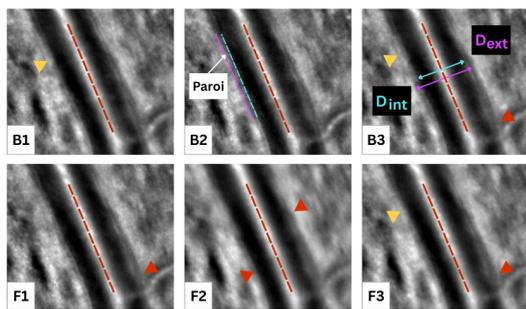


FIGURE 1 : S erie de flicker compos ee de 6 images acquises avant (B 1,2,3) et apr es (F 1,2,3) les flashes. En rouge le reflet central commun ( $V^R$ ) de la ROI. Les fl eches indiquent des zones de flou (rouge) et de faible contraste (jaune).

Nous nous int eressons au couplage neuro-vasculaire, gr ace   des s eries d'images d'OA prises avant et apr es stimulation par des flashes (Fig. 1), appel ees s eries flicker. Le stimulus lumineux induit une augmentation de la lumi ere des art eres et l'amincissement de leur paroi, donc une diminution du  $wlr$ .

Notre objectif clinique est de quantifier cette variation sur les sujets normaux et sur les patients atteints de maladies des petits vaisseaux du cerveau, telles que le Cadasil [8]. Cela requiert une segmentation pr ealable tr es pr ecise des parois art eriennes.

Nous avons propos e une approche de segmentation des images d'OA dans [11]. La m ethode repose sur deux  tapes : (i) la g en eration du masque binaire de la lumi ere des vaisseaux par apprentissage profond [12], (ii) la segmentation des parois gr ace   des mod eles de contours actifs param etriques d edi es, permettant l'extraction simultan ee d'interfaces approximativement parall eles [10], initialis ee   partir du masque binaire. L' tape (i) a  t e significativement am elior ee dans [1] en utilisant l'architecture DeepLabV3+ [2] avec un r eseau de base (backbone) Xception [3], offrant une meilleure segmentation des structures fines et complexes. Il en a r esult e une meilleure initialisation des contours actifs et des segmentations finales des parois art eriennes plus robustes et plus pr ecises. Cependant, le r esultat reste fortement d ependant de la qualit e de l'image et certaines zones ne peuvent pas  tre segment ees. En effet, les vaisseaux ne restent pas exactement dans le m eme plan, si bien qu'il y a des zones d efocalis ees (Fig. 1). Le contraste des parois peut  tre aussi tr es faible sur le bord externe. Ainsi, pour l'analyse des images de flicker, il a  t e d ecid e que l'expert m edical s electionne lui-m eme et manuellement la zone d'int er et, en pla cant quelques points sur le reflet central  $V^R$  du segment art eriel   analyser. La segmentation des images de flicker sera alors effectu ee sur cette zone d'int er et (ROI), en capitalisant sur la corr elation forte qui existe entre les 6 images de la s erie. Dans un premier temps, on effectuera la segmentation automatique dans une seule image, dite de r ef erence, qui doit  tre de la meilleure qualit e possible sur la ROI pour optimiser la probabilit e d'obtenir un r esultat pr ecis. Puis les 5 autres images seront segment ees en introduisant des couplages avec la segmentation de r ef erence, ces derniers orientant l' volution des contours actifs vers une solution coh erente avec la r ef erence, permettant ainsi de pallier les difficult es li ees   une qualit e moindre.

Cependant, si la sélection manuelle de la zone d'intérêt par l'expert médical est légitime, la sélection manuelle de la meilleure image pour initier la segmentation serait une étape très chronophage. Ainsi, dans cet article, nous proposons une méthode par apprentissage profond qui permet d'évaluer la qualité de l'image localement (puisque la qualité varie spatialement), puis globalement sur la zone d'intérêt, l'image de référence étant sélectionnée comme celle qui maximise ce score (Section 2). Puis nous introduisons des couplages avec cette première segmentation pour traiter les autres images flicker de moindre qualité (Section 3), les résultats expérimentaux démontrant l'intérêt de ces deux étapes (Section 4).

## 2 Analyse de qualité

Bien que largement étudiée dans d'autres modalités d'imagerie, l'évaluation de la qualité des images OA reste encore peu explorée. Pour les images UW-OCTA, la compétition de données DRAC sur l'analyse de la rétinopathie diabétique a fait émerger plusieurs approches d'apprentissage profond, avec des modèles de régression [9]. Dans ce travail, notre objectif est de développer une approche automatisée par patches pour évaluer la qualité des images en OA. L'intégration de la classe du vaisseau présent dans le patch est importante, car les critères de qualité diffèrent, notamment parce que les parois veineuses sont trop fines pour être visibles, contrairement aux parois artérielles. Fondée sur le modèle ResNet-50 [4], notre méthode intègre l'information de classe en introduisant une couche d'embedding (intégration), qui transforme les labels de classe en vecteurs de caractéristiques. Ces vecteurs sont ensuite combinés avec les caractéristiques profondes extraites de l'image d'entrée par le modèle, afin de générer un score de qualité.

### 2.1 Jeu de données OA

Notre modèle d'estimation de la qualité a été conçu sur un ensemble de 253 images d'OA, acquises avec la caméra rtx1 d'Imagine Eyes (Orsay, France), sans inclure de séries flicker. Elles proviennent de 45 sujets sains, 27 diabétiques et 33 atteints du syndrome Cadasil. Le jeu de données présente une grande diversité de niveaux de qualité et de configurations vasculaires, avec des vaisseaux de morphologies et calibres variés. La qualité de ces images varie spatialement (zones floues localisées). De chaque image, des patches de 256×256 pixels sont extraits avec un pas de 84 pixels (donc en chevauchement) ; ces patches sont ensuite filtrés à l'aide du squelette morphologique extrait du masque binaire des vaisseaux, pour ne retenir que ceux présentant un segment vasculaire centré, i.e. dont le centroïde de la plus grande composante se trouve à moins de 10% de la taille du patch par rapport à son centre. Les 4233 patches retenus ont été annotés manuellement par trois experts, qui ont défini la catégorie (artère, veine, confluence, etc.) et le score de qualité (mauvais = 0, moyen = 0.5, bon = 1) du patch en prenant en compte sa catégorie. Les scores de qualité sont moyennés entre annotateurs pour obtenir une évaluation plus précise et réduire les biais individuels.

## 2.2 Architecture

L'architecture du modèle est présentée dans la figure 2. Les patches d'images sont introduits dans un réseau de neurones convolutifs profond (DCNN), qui sert d'extracteur de caractéristiques. La classe du vaisseau (artère, veine, etc.) est traitée par une couche d'embedding (insertion) qui convertit les labels en un vecteur de caractéristiques dense de 32 dimensions. Ce vecteur est ensuite concaténé avec les caractéristiques extraites par le DCNN, le modèle de régression prédit le score de qualité à partir de cette fusion.

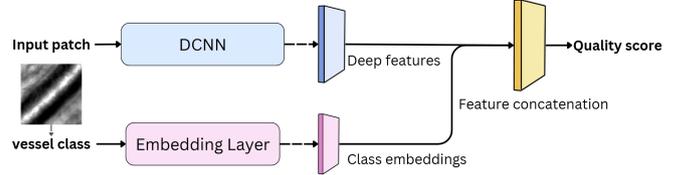


FIGURE 2 : Architecture du modèle.

## 3 Segmentation des séries flicker

### 3.1 Données flicker

Notre jeu de données flicker est composé de 38 séries d'images acquises auprès de 26 sujets sains. Chaque image est en niveaux de gris, de taille 1300×1300 pixels (1 pixel  $\approx 0.8\mu m^2$ ). Chaque série contient six images, trois capturées avant (B1, B2, B3) et trois après (F1, F2, F3) une série de flashes lumineux (Fig. 1). Un expert médical a défini le segment vasculaire à analyser en plaçant quelques points sur son reflet central. On appelle  $V^R$  la ligne déduite de ces points, régularisée par un contour actif [5] pour s'ajuster sur le reflet central, et commune à toutes les images de la série. Les patches permettant d'analyser la qualité locale des images sont centrés sur  $V^R$  et extraits avec un pas de 84 pixels. La qualité de chaque patch d'une image flicker est évaluée avec le modèle de la Section 2.2, et la moyenne des scores donne le score final de l'image.

### 3.2 Segmentation

La segmentation des parois artérielles est fondée sur un modèle de contours actifs dédié permettant de segmenter simultanément des interfaces approximativement parallèles. Le modèle général est défini par la fonctionnelle d'énergie suivante [11] :

$$E \left\{ b^{(i)} | V^{(R)}, b^{(k)}, b^{(l)} \right\} = \int_0^1 P(V^{(R)}(s), b^{(i)}(s)) + \varphi b^{(i)'}(s) + \rho(b^{(i)}(s) - b^{(k)}(s))^2 + \delta(b^{(i)'}(s) - b^{(l)'}(s))^2 ds \quad (1)$$

Dans ce modèle, les courbes  $V^{(j)}$  sont définies par leur distance  $b^{(j)}$  au reflet central  $V^{(R)}$ , avec  $b^{(j)}$  positif pour le côté 1 et négatif pour le côté 2 :  $V^{(j)} = V^{(R)} + b^{(j)}N^{(R)}$  où  $N^{(R)}$  est le vecteur unitaire normal à  $V^{(R)}$  (Fig. 3). La minimisation de (1) fait évoluer la courbe  $V^{(i)}$  sous l'action de différentes forces, issues du potentiel image  $P$  (1er terme, [13]) et de différentes contraintes : parallélisme par rapport à  $V^{(R)}$  (2e terme), proximité avec la courbe fixe  $V^{(k)}$  (3e terme),

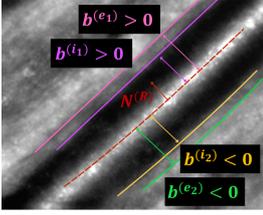


FIGURE 3 : Modèle géométrique des contours paramétriques.

parallélisme avec la courbe fixe  $V^{(l)}$  (4e terme). Dans la suite, on omettra le terme  $V^{(R)}$  commun pour alléger les notations.

L'image  $r \in \{1, \dots, 6\}$  obtenant le plus haut score moyen de qualité est sélectionnée comme image de référence et segmentée en premier grâce au modèle (1) selon la méthode proposée dans [11]. Pour les cinq autres images ( $i \in \{1, \dots, 6\} \setminus \{r\}$ ), on introduit des couplages avec la segmentation de l'image  $r$ . On minimise tout d'abord  $E \left\{ b_i^{(i_1)} \mid -b_i^{(i_2)}, b_r^{(i_1)} \right\} + E \left\{ b_i^{(i_2)} \mid -b_i^{(i_1)}, b_r^{(i_2)} \right\}$  pour favoriser la symétrie des courbes internes et leur parallélisme approximatif avec leurs correspondantes dans l'image  $r$ . Puis, on considère que l'épaisseur des parois artérielles ne change pas significativement, ce qui nous permet de définir une initialisation  $b_i^{(e_{1,2})[0]}$  des contours externes puis de les affiner en minimisant  $E \left\{ b_i^{(e_1)} \mid b_i^{(e_1)[0]}, b_i^{(i_1)} \right\} + E \left\{ b_i^{(e_2)} \mid b_i^{(e_2)[0]}, b_i^{(i_2)} \right\}$ .

Les pondérations des différentes forces ( $\varphi, \rho, \delta$ ) sont celles de [11], sans ajustement. À noter que ces poids sont relâchés au cours des itérations pour permettre aux courbes de s'ajuster.

Les diamètres sont estimés à partir des segmentations obtenues, d'où le  $wlr = \frac{D_{ext} - D_{int}}{D_{int}}$  (voir Fig. 1).

## 4 Résultats

### 4.1 Analyse de qualité

Notre ensemble de données comprend 4 233 patches d'images, répartis en ensembles d'entraînement (80 %), de validation (10 %) et de test (10 %), en veillant à conserver les patches d'un même patient dans un seul ensemble et à préserver la distribution des classes de vaisseaux. Nous avons testé deux configurations : ResNet-50 seul, puis notre architecture avec un DCNN Resnet-50 (Resnet50+CE). Le modèle, pré-entraîné sur ImageNet, a été entraîné avec des images normalisées selon les paramètres d'ImageNet et augmentées par des transformations horizontales, verticales et rotationnelles. Nous avons utilisé l'optimiseur AdamW et le planificateur ReduceLRon-Plateau. L'entraînement, réalisé sur un GPU Nvidia RTX, s'est déroulé sur 100 époques avec une taille de lot de 64 patches. Le modèle retenu est celui minimisant l'Erreur Quadratique Moyenne (RMSE) sur l'ensemble de validation. La fonction de coût L1 a été employée pour l'apprentissage, tandis que les performances ont été évaluées via l'Erreur Absolue Moyenne (MAE) et le RMSE. Pour analyser la variabilité, nous avons effectué cinq exécutions avec des noyaux aléatoires distincts. Le tableau 1 présente la moyenne et l'écart type des résultats. Les résultats obtenus montrent que l'insertion de classe améliore les performances du modèle avec une MAE de 0.145. Le modèle prédit un score pour chaque patch flicker, puis les scores sont moyennés pour obtenir un score global par image. Deux experts ont manuellement identifié les images de meilleure

TABLE 1 : Résultats de régression

Model	MAE	RMSE
Resnet50	0.150 $\pm$ 0.005	0.191 $\pm$ 0.006
Resnet50+CE	<b>0.145</b> $\pm$ 0.004	<b>0.184</b> $\pm$ 0.004

qualité dans la zone d'intérêt, servant ainsi de base de comparaison. Un exemple d'une ROI d'une série flicker est présenté dans la figure 4, avec les scores obtenus. Nous observons que les images altérées et floues obtiennent un score de qualité inférieur. Le quatrième patch, plus bruité que les autres, présente le score le plus bas, tandis que les patches contenant du flou près des contours affichent également de faibles scores. À l'inverse, le patch le mieux évalué est celui dont la paroi est la plus nette et contrastée de la séquence.

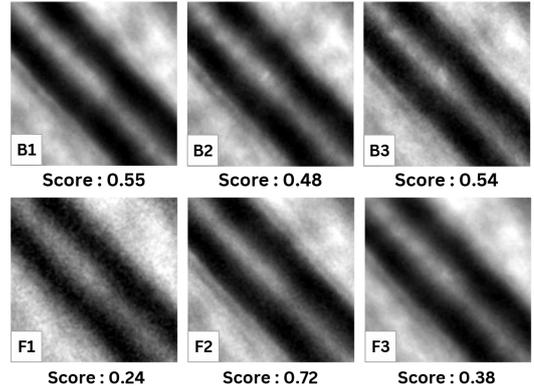


FIGURE 4 : Résultats de qualité sur la zone d'intérêt d'une séquence flicker.

Nous évaluons les performances du modèle en comparant ses prédictions avec les deux annotateurs à l'aide des métriques suivantes : l'Exactitude de l'Image Principale (EIP), qui mesure la correspondance entre l'image la mieux classée par le modèle et le premier choix des annotateurs ; l'Exactitude de Correspondance Partielle du Modèle (ECPM), qui vérifie si l'image la mieux classée par le modèle figure parmi les trois premières images des annotateurs ; et l'Exactitude de Correspondance Partielle des Annotateurs (ECPA), qui mesure si le premier choix des annotateurs est inclus dans les trois meilleures prédictions du modèle. Ces métriques permettent d'évaluer l'alignement entre les prédictions du modèle et les annotations humaines. Les résultats sont présentés dans le tableau 2.

TABLE 2 : Analyse de correspondance entre les prédictions du modèle et les annotations (en pourcentage)

Annotateur	EIP	ECPM	ECPA
1	34.21	73.68	86.84
2	36.84	71.05	81.58

L'EIP est relativement faible (34-37%), ce qui indique que le modèle ne parvient pas toujours à sélectionner l'image classée en tête par les annotateurs. En revanche, l'ECPM donne de meilleurs résultats (71-73%), suggérant que le modèle place fréquemment des images pertinentes parmi les premières sélections des annotateurs. Enfin, l'ECPA affiche des scores encore

plus élevés (81-86%), ce qui montre que les annotateurs retrouvent très souvent leur première image choisie parmi les trois premières prédictions du modèle.

## 4.2 Segmentation

Un expert médical a segmenté toute la base de données des images de flicker avec nos outils en mode supervisé [11]. Chaque image de la série est traitée indépendamment des autres, mis à part la ligne de référence commune  $V^{(R)}$ . Dans le mode supervisé, l'expert peut réinitialiser les contours actifs jusqu'à ce qu'il soit satisfait du résultat. Ces segmentations servent de vérité terrain. Pour évaluer l'apport de la méthode proposée, nous avons réalisé 3 expérimentations :

- Expérience 0 : aucun couplage inter-images [11],
- Expérience 1 : couplages inter-images avec sélection aléatoire de l'image de référence,
- Expérience 2 : sélection de la meilleure image par apprentissage profond et couplages inter-images.

Pour l'évaluation quantitative, nous avons mesuré le RMSE entre la vérité terrain et la segmentation obtenue ( $V^{i1,2}$ ,  $V^{e1,2}$ ). Nous avons également mesuré, en  $\mu m$ , les erreurs faites sur les diamètres internes et externes, puis sur le  $wlr$  (Table 3). Les erreurs moyennes ont été calculées sur chaque série puis moyennées sur les séries.

TABLE 3 : Evaluation quantitative. RMSE sur les interfaces internes  $V^{i1,2}$  et externes  $V^{e1,2}$  (pix), erreurs moyennes sur les diamètres internes  $D_{int}$  et externes  $D_{ext}$  ( $\mu m$ ), et sur le  $wlr$ .

Expérience	$V^{i1,2}$	$V^{e1,2}$	$D_{int}$	$D_{ext}$	$wlr$
0 [11]	0.582 $\pm 0.745$	1.761 $\pm 1.657$	<b>0.179</b> $\pm 0.478$	0.905 $\pm 2.571$	0.007 $\pm 0.037$
1	<b>0.526</b> $\pm 0.836$	1.860 $\pm 1.883$	0.308 $\pm 0.647$	1.389 $\pm 2.676$	0.014 $\pm 0.036$
2	0.529 $\pm 0.776$	<b>1.488</b> $\pm 1.602$	0.196 $\pm 0.472$	<b>0.581</b> $\pm 2.321$	<b>0.003</b> $\pm 0.022$

Les résultats sont très précis dans toutes les configurations pour les interfaces internes (RMSE de l'ordre de 0.5 pixel), les couplages inter-images apportant peu. Ce n'est pas étonnant car ces bords sont bien contrastés sur les segments choisis par l'expert. En conséquence, les mesures de diamètres internes sont elles aussi excellentes. Pour les interfaces externes, la sélection de la meilleure image et le couplage inter-images amènent un gain significatif (RMSE de  $1.49 \pm 1.60$  contre  $1.76 \pm 1.66$ ) alors que le couplage inter-images avec sélection aléatoire de l'image de référence dégrade le résultat, ce qui démontre l'importance de notre étape de sélection automatique de la meilleure image et son efficacité. Ainsi, la méthode proposée conduit aux meilleures mesures de  $wlr$ , avec une erreur moyenne de  $0.003 \pm 0.022$ , ce qui est très bon et nettement mieux que dans l'approche de référence ( $0.007 \pm 0.037$ ).

## 5 Conclusion

Nous proposons une méthode d'évaluation de la qualité des images d'OA basée sur l'apprentissage profond. Cette étape permet d'améliorer significativement la segmentation des images flicker en utilisant la segmentation de l'image de

meilleure qualité comme régularisation pour la segmentation des images de moindre qualité. Ainsi nous obtenons des mesures significativement plus précises du  $wlr$ , avec comme seule intervention de l'expert médical la sélection de la zone d'intérêt.

## Références

- [1] A AISSA, F ROSSANT, H URIEN et M PAQUES : Deep learning-based segmentation of retinal vessels in adaptive optics ophthalmoscopy images. *ISBI*, pages 1–5, 2024.
- [2] LC CHEN, Y ZHU, G PAPANDREOU, F SCHROFF et H ADAM : Encoder-decoder with atrous separable convolution for semantic image segmentation. *In ECCV*, 2018.
- [3] François CHOLLET : Xception : Deep learning with depthwise separable convolutions. *CVPR*, 2017.
- [4] K HE, X ZHANG, S REN et J SUN : Deep residual learning for image recognition. *CVPR*, 2016.
- [5] M KASS, A WITKIN et D TERZOPOULOS : Snakes : Active contour models. *International journal of computer vision*, 1(4):321–331, 1988.
- [6] E KOCH, D ROSENBAUM, A BROLLY, J SAHEL, P CHAUMET-RIFFAUD, X GIRERD, F ROSSANT et M PAQUES : Morphometric analysis of small arteries in the human retina using adaptive optics imaging : relationship with blood pressure and focal vascular changes. *Journal of hypertension*, 32(4):890–898, 2014.
- [7] T LUO, TJ GAST, TJ VERMEER et SA BURNS : Retinal vascular branching in healthy and diabetic subjects. *IOVS*, 58:2685–2694, 2017.
- [8] M PAQUES, V KRIVOSIC, D CASTRO-FARIAS, C DULIÈRE, D HERVÉ, C CHAUMETTE *et al.* : Early remodeling and loss of light-induced dilation of retinal small arteries in cadasil. *JCBFM*, 44:1089 – 1101, 2024.
- [9] B QIAN, H CHEN, X WANG, Z GUAN, T LI, Y JIN, Y WU, Y WEN, H CHE, G KWON *et al.* : Drac 2022 : A public benchmark for diabetic retinopathy analysis on ultra-wide optical coherence tomography angiography images. *Patterns*, 5(3), 2024.
- [10] F ROSSANT, I BLOCH, I GHORBEL et M PAQUES : Parallel double snakes. application to the segmentation of retinal layers in 2d-oct for pathological subjects. *Pattern Recognition*, 48:3857–3870, 2015.
- [11] F ROSSANT, I BLOCH, I TRIMÈCHE, J de BELLESCIZE, DC FARIAS, V KRIVOSIC, H CHABRIAT et M PAQUES : Characterization of retinal arteries by adaptive optics ophthalmoscopy image analysis. *IEEE TBME*, 2024.
- [12] I TRIMECHE, F ROSSANT, I BLOCH et M PAQUES : Fully automatic cnn-based segmentation of retinal bifurcations in 2d adaptive optics ophthalmoscopy images. *IPTA*, 2020.
- [13] C XU et JL PRINCE : Generalized gradient vector flow external forces for active contours. *Signal processing*, 71(2):131–139, 1998.