

# Régularisation directionnelle pour la segmentation de structures curvilignes\*

Odyssée MERVEILLE<sup>1</sup>, Olivia MIRAUCOURT<sup>2,3</sup>, Stéphanie SALMON<sup>3</sup>, Nicolas PASSAT<sup>4</sup>, Hugues TALBOT<sup>2</sup>

<sup>1</sup>Université de Strasbourg, ICube, CNRS (UMR 7357), France

<sup>2</sup>Université Paris-Est – ESIEE, LIGM, UMR, CNRS 8049, France

<sup>3,4</sup> Université de Reims Champagne-Ardenne, <sup>3</sup>LMR, <sup>4</sup>CRéSTIC, France

merveille@unistra.fr, hugues.talbot@esiee.fr, prenom.nom@univ-reims.fr

**Résumé** – La segmentation de structures curvilignes est une tâche cruciale dans de nombreuses applications médicales comme la segmentation de vaisseaux sanguins en 2 et 3 dimensions. Néanmoins, ces structures sont très sensibles au bruit de par leur finesse et faible densité dans les images, rendant leur segmentation difficile. L’orientation locale de ces structures peut apporter une information utile en segmentation. Nous proposons d’utiliser cette information, estimée par des méthodes récentes de traitement d’image, comme *a priori* dans un terme de régularisation pour modèles variationnels. Ce terme, en plus de conserver un fort pouvoir régularisant dans l’ensemble de l’image, permet de mieux préserver les structures curvilignes. Nous présentons des résultats à la fois sur des images synthétiques et réelles à 2 dimensions.

**Abstract** – Curvilinear structure segmentation is an important task, with many applications in medical image analysis such as vessel segmentation, both in 2D and 3D. However, this task is challenging due to the spatial sparsity of these objects, implying a high sensitivity to noise. An important cue in this context is the local orientation of the curvilinear structures. Using this information, it is possible to regularize the structures without destroying their integrity. In this article, we take advantage of recent advances in orientation estimation to propose a directional regularization prior for curvilinear structures, suitable for use in a variational framework. We provide illustrative results on both synthetic and real 2D data.

## 1 Introduction

Les structures curvilignes dans les images  $nD$  présentent une taille significativement plus petite dans  $n - 1$  dimensions. La détection de ces structures (vaisseaux sanguins, neurones, *etc.*) est une étape obligatoire et difficile pour de nombreuses applications biomédicales.

Plusieurs facteurs font des structures curvilignes des objets difficiles à traiter en analyse d’images : elles présentent une géométrie souvent complexe (fines, allongées, tortueuses, bifurquées, *etc.*), et leur densité est souvent faible dans les images. Ainsi, les structures curvilignes sont naturellement plus fragiles et sensibles au bruit que la plupart des autres structures.

Parmi les méthodes de filtrage de structures curvilignes, la *vesselness* de Frangi [3] est la référence. Cette approche, basée sur les dérivées secondes de l’image, fournit une *caractéristique d’intensité*, donnant pour chaque pixel une probabilité d’appartenance à une structure curviligne ; et une *caractéristique de direction*, estimant la direction locale de la structure sous-jacente. Nous avons récemment développé un opérateur appelé RORPO [5], basé sur un paradigme différent de la *vesselness* de Frangi, et fournis-

sant également ces deux caractéristiques avec de meilleures performances.

Dans cet article, nous proposons un nouveau terme de régularisation pour modèle variationnel utilisant une caractéristique d’intensité mais aussi de direction des structures curvilignes. Ceci nous permet de mieux les préserver et induire des reconnections, tout en préservant une régularisation isotrope dans le reste de l’image.

## 2 Modèle de segmentation

### 2.1 Problème et notations

Notons  $X = \mathbb{R}^{M \times N}$  l’espace vectoriel Euclidien et  $f \in X$  une image de taille  $M \times N$ . Nous considérons le problème de minimisation suivant :

$$\min_{u \in X} F(u, f) + \lambda G(u) \quad (1)$$

où  $F$  est un terme d’attache aux données,  $G$  un terme de régularisation et  $\lambda \in \mathbb{R}$  un coefficient de pondération.

La variation totale (TV) est un terme de régularisation classiquement utilisé :

$$\text{TV}(u) = \|\nabla u\|_{2,1} = \sum_{i,j} \sqrt{(u_{ij}^x)^2 + (u_{ij}^y)^2}$$

où  $\nabla u = (u^x, u^y)$  est le gradient 2D de  $u$ .

\*Ce travail a été financé par l’Agence Nationale de la Recherche (ANR-12-MONU-0010).




FIGURE 1 – (a) Régularisation par la TV (gauche), la TV pondérée [6] (centre) et notre TV directionnelle (droite). Plus la couleur est foncée plus la régularisation est importante. (b) Comparaison du gradient  $\nabla$  (gauche) et du gradient directionnel  $\nabla_D$  (droite).

## 2.2 Principe

La TV minimise la norme du gradient, ce qui pénalise les contours des structures. Or, les structures curvilignes en sont essentiellement composées, les rendant très sensibles à la TV qui a tendance à les faire disparaître.

Miracourt *et al.* [6] ont proposé une TV pondérée par la caractéristique d'intensité de la *vesselness* de Frangi, pour en obtenir une régularisation spatialement variante, réduisant ainsi la pénalisation excessive des structures curvilignes. Cependant, ces structures curvilignes restent généralement assez bruitées et déconnectées du fait de leur faible régularisation.

Nous proposons un terme de régularisation directionnelle plus adapté aux structures curvilignes, en considérant à la fois une caractéristique d'intensité mais également de direction. Ceci nous permet de conserver une forte régularisation à l'extérieur, mais aussi à l'intérieur des structures curvilignes, seulement dans la direction de leur axe.

## 2.3 Gradient directionnel

Notre régularisation est basée sur un gradient directionnel  $\nabla_d$ , intégrant une caractéristique d'intensité et de direction des structures curvilignes.

Notons  $\mathbf{V} = (\mathbf{v}_1, \dots, \mathbf{v}_p)$  la famille génératrice de  $\mathbb{R}^{M \times N}$  de  $p$  vecteurs contenant toutes les orientations discrètes d'un voisinage  $k \times k$  tel que  $p = 2(n^2 - n + 1)$  et  $n = \frac{k-1}{2}$  (voir figure 2). On définit ainsi le gradient directionnel d'une image  $u$  dans les directions de  $\mathbf{V}$  au pixel  $(i, j)$  par :

$$(\nabla_d u)_{ij} = \left( D_{ij}^1 u_{ij}^{v_1}, D_{ij}^2 u_{ij}^{v_2}, \dots, D_{ij}^p u_{ij}^{v_p} \right) \quad (2)$$

Avec  $u_{ij}^{v_k}$  la composante selon  $\mathbf{v}_k$  du gradient  $\nabla_d u$  au pixel  $(i, j)$ ; et  $D \in X^p$  une matrice de poids dépendant de la caractéristique d'intensité  $\Phi \in X$  et de direction  $\Delta_{ij} \in X^2$  de laquelle on extrait les coefficients  $d \in X^p$  (voir Section 3.1) :

$$D_{ij}^q = d_{ij}^q \Phi_{ij} + (1 - \Phi_{ij}), \quad 1 \leq q \leq p$$

$$\sum_{q=1}^p D_{ij}^q = 1, \quad 0 \leq i < M \text{ et } 0 \leq j < N \quad (3)$$




FIGURE 2 – Exemple de familles génératrices  $\mathbf{V}$  pour différentes valeurs de  $n$ .

Intuitivement, si un pixel  $(i, j)$  n'appartient pas à une structure curviligne, alors  $\Phi_{ij} = 0$  et donc  $D_{ij}^q = 1 \forall q \in \llbracket 1, p \rrbracket$ . De ce fait,  $(\nabla_d u)_{ij} = (u_{ij}^{v_1}, u_{ij}^{v_2}, \dots, u_{ij}^{v_p})$  qui est un gradient isotrope. Au contraire, si un pixel  $(i, j)$  appartient à une structure curviligne, alors  $\Phi_{ij} = 1$  et donc  $D_{ij}^q = d_{ij}^q \forall q \in \llbracket 1, p \rrbracket$  qui codent l'orientation de la structure (par exemple, si une structure curviligne est orientée selon  $\mathbf{v}_1$ , alors  $d_{ij}^1 = 1$  et  $d_{ij}^q = 0 \forall q \in \llbracket 2, p \rrbracket$ ). Ainsi  $(\nabla_d u)_{ij} = (d_{ij}^1 u^{v_1}, d_{ij}^2 u^{v_2}, \dots, d_{ij}^p u^{v_p})$ , qui est un gradient anisotrope.

Ainsi, seuls les contours extrémaux des structures curvilignes apparaissent avec ce nouveau gradient (voir figure 1.b). Minimiser la norme  $\ell^1$  du gradient directionnel (*i.e.* la TV directionnelle) est donc plus pertinent car les structures curvilignes sont moins pénalisées et ainsi mieux préservées, tout en maintenant une forte régularisation.

## 2.4 Modèle de segmentation directionnel

Nous proposons une segmentation variationnelle basée sur notre TV directionnelle :

$$\underset{u \in [0,1]^{N \times N}}{\text{minimize}} \langle c_f, u \rangle_F + \lambda \|\nabla_d u\|_{2,1} \quad (4)$$

Où  $\|\nabla_d u\|_{2,1}$  est la variation totale directionnelle tandis que  $\langle c_f, u \rangle_F$  est l'attache aux données de Chan-Vese [2] telle que  $(c_f)_{ij} = (c_1 - f_{ij})^2 - (c_2 - f_{ij})^2$  et  $\langle u, v \rangle_F = \sum_{ij} u_{ij} v_{ij}$  est la norme de Frobenius. Les constantes  $c_1$  et  $c_2$  sont respectivement les valeurs moyennes du premier plan et de l'arrière plan de l'image initiale  $f$ .

## 3 Implantation

Nous présentons dans cette section des détails pour calculer la variation totale directionnelle et obtenir les résultats de segmentation directionnelle de la Section 4. Dans la suite, nous utiliserons la famille génératrice de vecteurs  $\mathbf{V} = (\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \mathbf{v}_4)$  *i.e.* pour  $n = 1$  (figure 2.a).

### 3.1 Intégration des caractéristiques d'intensité et de direction




FIGURE 3 – Décomposition du vecteur de direction  $\Delta_{ij}$  sur les vecteurs de  $V$ .

Les caractéristiques d'intensité et de direction peuvent provenir de n'importe quel filtre. Dans [5] nous avons montré que RORPO fournit des caractéristiques de structures curvilignes très robustes. C'est donc celles que nous utiliserons dans la suite de cet article. La caractéristique d'intensité  $\Phi$  doit seulement être normalisée entre  $[0, 1]$  dans notre approche, alors que la caractéristique de direction requiert une transformation.

Notons  $\Delta \in X^2$  la caractéristique de direction normalisée, telle que  $\Delta_{ij} = (\Delta_{ij}^x, \Delta_{ij}^y)$  est le vecteur donnant la direction locale d'une structure curviligne au pixel  $(i, j)$ . Les  $d_{ij}^q$  sont les coefficients issus de la décomposition de  $\Delta_{ij}$  sur  $V$ . Pour garantir un gradient réellement directionnel, nous imposons que seul les deux coefficients de décompositions  $d_{ij}^m$  et  $d_{ij}^n$  associés aux deux vecteurs  $v_m$  et  $v_n$  encadrant  $\Delta_{ij}$  soient non nuls (voir figure 3) :

$$\Delta_{ij} = \sum_{q=1}^p d_{ij}^q v_q = d_{ij}^m v_m + d_{ij}^n v_n \quad (5)$$

A partir de l'Équation 5, on dérive le système linéaire :

$$\begin{aligned} d_{ij}^m v_m \cdot v_m + d_{ij}^n v_n \cdot v_m &= \Delta_{ij} \cdot v_m \\ d_{ij}^m v_m \cdot v_n + d_{ij}^n v_n \cdot v_n &= \Delta_{ij} \cdot v_n \end{aligned}$$

Étant donné que nous considérons  $V = (v_1, v_2, v_3, v_4)$ , l'angle entre deux vecteurs adjacents  $v_m$  et  $v_n$  est constant et  $v_m \cdot v_n = \frac{\sqrt{2}}{2}$ . Nous obtenons ainsi :

$$\begin{aligned} d_{ij}^m &= 2\Delta_{ij} \cdot v_m - \sqrt{2}\Delta_{ij} \cdot v_n \\ d_{ij}^n &= 2\Delta_{ij} \cdot v_n - \sqrt{2}\Delta_{ij} \cdot v_m \end{aligned}$$

### 3.2 Algorithme

Notons  $\text{prox}_\varphi$  l'opérateur proximal d'une fonction  $\varphi : X \rightarrow \mathbb{R}$  :

$$\text{prox}_\varphi x = \arg \min_{y \in X} \varphi(y) + \frac{1}{2} \|x - y\|_{2,2}^2 \quad (6)$$

Combettes et Wajs ont prouvé que l'équation (4) avec une TV classique pouvait être résolue par un algorithme du point proximal. Nous proposons donc d'appliquer cet algorithme à notre modèle de segmentation directionnelle :

$$u_{n+1} = \text{prox}_{\gamma h}(u_n - \gamma c_f) \quad (7)$$

où  $h = \lambda \|\nabla_d u\|_{2,1} + \iota_{[0,1]^{M \times N}}(u)$ ,  $\gamma$  est un pas et  $\iota_{[0,1]^{M \times N}}$  la fonction indicatrice définie par :

$$\iota_{[0,1]^{M \times N}}(u) = \begin{cases} 0 & \text{si } u \in [0, 1]^{M \times N} \\ +\infty & \text{sinon} \end{cases}$$

L'opérateur proximal de  $\gamma h$  peut être calculé par une approche duale [1], conduisant à appliquer un algorithme de gradient projeté (voir Algorithme 1).

Algorithme 1 utilise les notations suivantes :

- $P_{B_{0,1}}$  est la projection sur  $B_{0,1} = \{x, 0 \leq x_{ij} \leq 1\}$
- $\text{div}_d$  est l'opérateur adjoint de  $\nabla_d$  tel que  $\langle -\text{div}_d p, u \rangle_X = \langle p, \nabla_d u \rangle_{X^4}, \forall p \in X^4, \forall u \in X$ .

---

#### Algorithme 1 : Gradient projeté rapide

---

**Données :**  $o \in X, x_0 \in X^4, z_1 = x_0$  et  $t_0 = 1$

**pour**  $n = 1$  à  $N$  **faire**

$$y_n = z_n + \frac{1}{8\lambda} \nabla_d (P_{B_{0,1}}[o - \lambda \text{div}_d(z_n)])$$

$$x_n = P_p[y_n]$$

$$t_{n+1} = \frac{1 + \sqrt{4t_n^2 + 1}}{2}$$

$$\lambda_n = \frac{t_n - 1}{t_{n+1}}$$

$$z_{n+1} = x_n + \lambda_n(x_n - x_{n-1})$$

**fin**

**retourner**  $P_{B_{0,1}}[o - \lambda \text{div}_d(x_N)]$  ; //  $\text{prox}_{\gamma h}(o)$

---

## 4 Résultats

Dans cette section, nous présentons des résultats sur des images synthétiques et réelles. Nous comparons nos résultats avec le modèle de Chan-Vese [2].

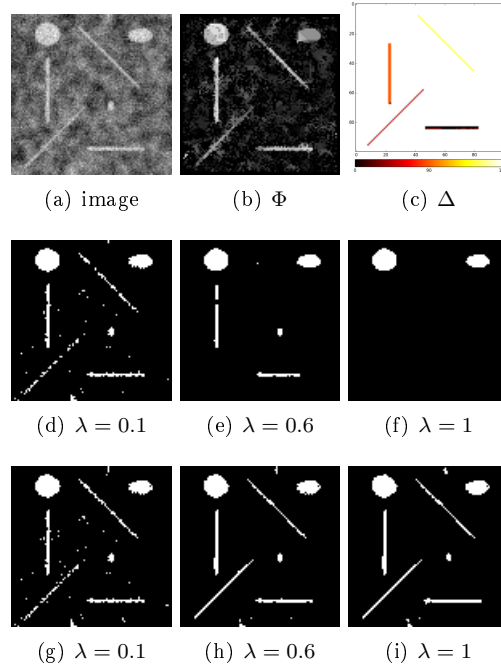


FIGURE 4 – Segmentation de l'image (a) avec le modèle de Chan-Vese (d-f) et notre modèle directionnel (g-i) pour différentes valeurs de  $\lambda$ . Les caractéristiques d'intensité (b) et de direction (c) par RORPO.

## 4.1 Images synthétiques

Pour valider notre méthode, nous avons segmenté une image synthétique contenant des structures curvilignes et isotropes avec différents niveaux de régularisation ( $\lambda$ ). Les résultats sont présentés dans la figure 4.

Pour de faibles niveaux de régularisation, les résultats des deux méthodes sont semblables, ce qui est attendu car elles s'appuient sur la même attache aux données.

Plus  $\lambda$  augmente, plus les structures curvilignes disparaissent avec le modèle de Chan-Vese. Tandis que notre modèle permet à la fois de mieux préserver les structures curvilignes, mais aussi de les reconnecter grâce à la régularisation directionnelle.

## 4.2 Images rétiniennes

Nous avons enfin comparé notre segmentation sur la base Drive de 20 images de fond d'œil [7]. Nous avons calculé la précision (Pre) à partir des vrais/faux positifs (VP/FP) et vrais/faux négatifs (VN/FN). Les résultats quantitatifs sont présentés dans la Table 1 et le résultat sur la première image de la base est illustré en figure 5.

La précision de notre méthode est très proche de l'état de l'art actuel (voir [4]), bien que nous ne proposons pas une méthode dédiée à la segmentation vasculaire, mais un terme de régularisation général. Celle-ci peut être intégrée à des méthodes plus complexes de segmentation, débruitage *etc.*, à la place de la TV classique, afin d'améliorer les résultats sur les structures curvilignes.

Quantitativement, notre méthode est effectivement plus performante que la TV classique, bien que la différence de précision reste faible. En effet, l'amélioration porte sur les extrémités des vaisseaux, qui ne représentent qu'une faible partie de l'image, et donc une variation minimale de précision. Néanmoins, mieux segmenter ces petits vaisseaux est crucial dans de nombreuses applications.

	VP	VN	Pre
Chan-Vese [2]	0.656	0.985	0.9421
Proposed segmentation	0.690	0.981	0.9434
Staal [7]	-	-	0.9442
Human observer	-	-	0.9470

TABLE 1 – Résultat quantitatifs de la segmentation de la base Drive.

## Références

[1] A. Beck and M. Teboulle. Fast gradient-based algorithms for constrained total variation image denoising and deblurring problems. *IEEE Trans. Image Process.*, 18(11) :2419–2434, 2009.

[2] T.F. Chan and Vese L.A. Active contours without edges. *IEEE Trans. Image Process.*, 10(2) :266–277, 2001.

[3] A.F. Frangi, W.J. Niessen, K.L. Vincken, and M.A. Viergever. Multiscale vessel enhancement filtering. In *Proc. Med.*

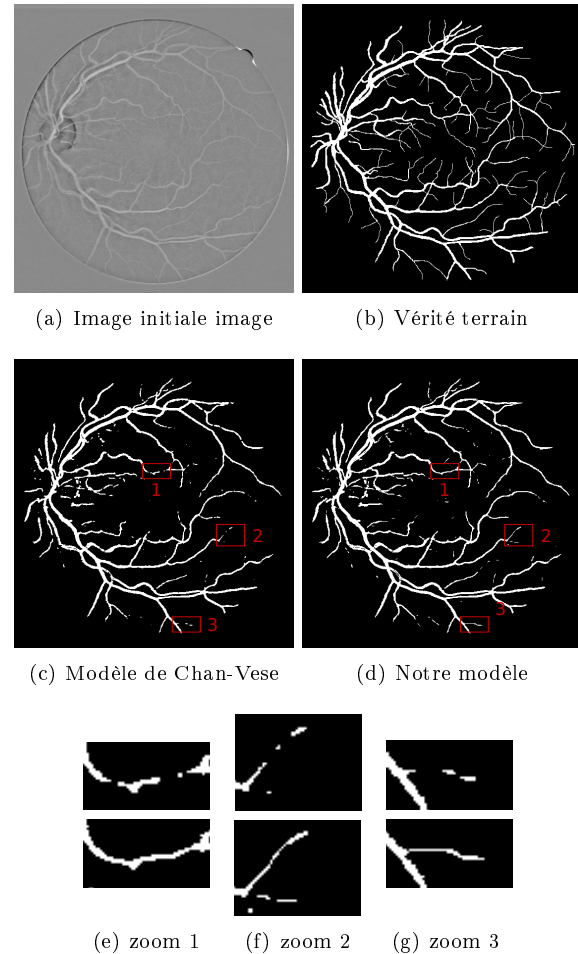


FIGURE 5 – Comparaison de la segmentation de Chan-Vese (c) avec notre segmentation directionnelle (d) sur la première image de la base DRIVE pré traitée par un filtre médian (a). (b) est la vérité terrain, et (e–g) montrent des zooms sur nos résultats (en bas) et ceux de Chan-Vese (en haut).

*Image Computing & Comp.-Assist. Intervention (MIC-CAI)*, volume 1496, pages 130–137. Springer, 1998.

[4] M. M. Fraz, P. Remagnino, A. Hoppe, B. Uyyanonvara, et al. Blood vessel segmentation methodologies in retinal images—a survey. *Comput. Meth. Programs Biomed.*, 108(1) :407–433, 2012.

[5] O. Merveille, H. Talbot, L. Najman, and N. Passat. Curvilinear structure analysis by ranking the orientation responses of path operators. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2017.

[6] O. Miraucourt, A. Jezierska, H. Talbot, S. Salmon, and N. Passat. Variational method combined with Frangi vesselness for tubular object segmentation. *Comput. Math. Biomed Eng.*, pages 485–488, 2015.

[7] J.J. Staal, M.D. Abramoff, M. Niemeijer, M.A. Viergever, and B. van Ginneken. Ridge based vessel segmentation in color images of the retina. *IEEE Trans. Med. Imag.*, 23(4) :501–509, 2004.