

Segmentation d’images texturées en grande dimension. Application à l’analyse d’écoulements multiphasiques.[†]

Barbara PASCAL, Thomas BUSSER, Nelly PUSTELNIK, Patrice ABRY, Valérie VIDAL

Univ Lyon, ENS de Lyon, Univ Claude Bernard Lyon 1, CNRS, Laboratoire de Physique, F-69342 Lyon, France
prenom.nom@ens-lyon.fr

Résumé – L’étude de la dynamique d’écoulements multiphasiques, enjeu majeur en géosciences, peut se formaliser comme un problème de segmentation de textures. Plusieurs approches de segmentation reposant sur une estimation conjointe de régularité et puissance locales, pénalisée par un terme de variation totale, pour favoriser des solutions constantes par morceaux, sont proposées et comparées à des approches de l’état de l’art, et sur des textures synthétiques et sur un écoulement gaz-liquide traversant une mousse solide.

Abstract – Studying the dynamics of multiphase flows, a key challenge in geosciences, can be framed as texture segmentation. Several segmentation procedures, relying on a joint estimation of local regularity and power, penalized by total variation, to favor piecewise constant solutions, are proposed and compared to state-of-the-art texture segmentation approaches, both using synthetic textures and gas-liquid flow through a solid foam.

1 Introduction

Dynamiques d’écoulement multiphasiques et segmentation de textures. L’étude de la dynamique des écoulements multiphasiques est un enjeu majeur en géosciences, par exemple pour la récupération assistée du pétrole, la décontamination des sols ou le stockage du CO₂. Du point de vue de la physique fondamentale, ces écoulements sont encore loin d’être caractérisés [1] et leur étude se reformule souvent comme un problème de segmentation de textures. De manière plus générale, les problèmes de segmentation d’images, et plus spécifiquement d’images texturées, sont cruciaux en physique expérimentale, puisqu’ils permettent le traitement automatique de gros volumes d’images (comme par exemple des vidéos) sans requérir l’intervention systématique de l’utilisateur, et ainsi permettent une extraction automatique de paramètres physiques, potentiellement affranchie du biais relatif à l’observateur.

Etat de l’art. La segmentation d’images est un problème bien documenté dans la littérature avec des méthodes telles que les algorithmes par ligne de partage des eaux [2], Chan-Vese [3], ou K-means [4]. Lorsqu’il s’agit de segmenter des images texturées, l’approche usuelle consiste à extraire des descripteurs locaux puis à appliquer les méthodes mentionnées précédemment sur ces descripteurs de façon à identifier des zones homogènes en terme de descripteurs. Une approche en deux temps va impacter la précision de la détection des interfaces de changement qui est cruciale lors de l’extraction de certains paramètres physiques. Récemment Yuan *et al.* [5] ont étudié l’intérêt de réaliser simultanément l’estimation des descripteurs et la segmentation grâce à une factorisation matricielle. Plus ré-

cemment [6] propose également une procédure simultanée où le descripteur de texture est la *régularité locale*, mesurant l’invariance d’échelle d’une texture, mais avec des coûts de calculs souvent trop important pour être mis en oeuvre sur des données expérimentales.

Le défi majeur est donc de proposer des méthodes de segmentation de textures faiblement supervisées (ayant peu de paramètres), permettant une détection précise des interfaces et avec des coûts de calcul raisonnables pour envisager le traitement de séquences d’images de grande taille (e.g. 10⁷ pixels). **Objectifs, contributions et organisation de l’article.** Ce travail prolonge [7] en proposant une approche de segmentation de textures construite sur régularité et puissance locales (cf. Sec. 2). Estimation et segmentation sont réalisées simultanément via une minimisation d’une erreur quadratique pénalisée par variation totale. Afin d’étudier l’impact de la pénalisation dans ce type de formulation, deux pénalisations, *jointe* ou *couplée*, sont proposées (cf. Sec. 3). Ces approches sont comparées entre elles et à l’état-de-l’art, à la fois sur des textures synthétiques (cf. Sec. 3) et sur un exemple d’écoulement multiphasique traversant une mousse solide, dans une cellule ouverte à géométrie semi-confinée (dite “de Hele-Shaw”) (cf. Sec. 4).

2 Texture fractale

Modèle – Dans ce travail, on dira qu’une texture (de taille $N_1 \times N_2$ pixels) est fractale (ou invariante d’échelle), lorsqu’elle satisfait en tout pixel $\underline{n} \in \Omega = \{1, \dots, N_1\} \times \{1, \dots, N_2\}$:

$$\mathcal{L}_{j,\underline{n}} \sim \eta_{\underline{n}} 2^{jh_{\underline{n}}}$$

[†] Ce travail s’inscrit dans cadre du Défi Imag’IN CNRS SIROCCO.




FIGURE 1 – Différentes méthodes de segmentation appliquées à une texture synthétique et scores de classification.

où $\mathcal{L}_{j,\underline{n}}$ correspond à une quantité multiéchelle associée à la texture analysée, par exemple la valeur absolue des coefficients d'ondelettes ou les coefficients d'ondelettes dominants [8] à l'échelle 2^j et la position \underline{n} et où $h_{\underline{n}}$ et $\eta_{\underline{n}}$ constituent les attributs de régularité et puissance locales de la texture. De plus, une texture sera dite homogène lorsque les attributs de régularité et puissance locale $h_{\underline{n}}$ et $\eta_{\underline{n}}$ ne dépendent pas de la position : $h_{\underline{n}} \equiv H$, $\eta_{\underline{n}} = \eta$.

Le comportement log-linéaire à travers des échelles :

$$\log_2(\mathcal{L}_{j,\underline{n}}) \simeq \log_2(\eta_{\underline{n}}) + j h_{\underline{n}}, \text{ quand } 2^j \rightarrow 0 \quad (1)$$

permet, en théorie, l'estimation de $h_{\underline{n}}$ et $\log_2(\eta_{\underline{n}})$ par une régression linéaire.

Estimation – En posant $\boldsymbol{\eta} = (\eta_{\underline{n}})_{\underline{n} \in \{1, \dots, N_1\} \times \{1, \dots, N_2\}}$ et $\mathbf{v} = \log_2(\boldsymbol{\eta})$, la régression linéaire (1) se réécrit comme la minimisation de la fonctionnelle :

$$\Phi(\mathbf{v}, \mathbf{h}; \mathcal{L}) = \frac{1}{2} \sum_j \|\mathbf{v} + j\mathbf{h} - \log_2 \mathcal{L}_j\|_{\text{Fro}}^2. \quad (2)$$

La fonction $\Phi(\mathbf{v}, \mathbf{h}; \mathcal{L})$ est différentiable, de gradient lipschitzien et fortement convexe, elle possède donc en particulier un unique minimum, calculable analytiquement. Néanmoins la résolution directe du problème non régularisé

$$(\hat{\mathbf{v}}^{\text{RL}}, \hat{\mathbf{h}}^{\text{RL}}) = \arg \min_{\mathbf{v}, \mathbf{h}} \Phi(\mathbf{v}, \mathbf{h}; \mathcal{L}) \quad (3)$$

n'est pas satisfaisante, car les estimées locales $\hat{\mathbf{v}}^{\text{RL}}$ et $\hat{\mathbf{h}}^{\text{RL}}$ sont affectées par de très fortes variances. Des régularisations de type Tikhonov pourraient être considérées de façon à lisser les estimées. Dans ce travail nous préférons cependant utiliser un terme de régularisation qui va favoriser le caractère constant par morceaux des estimées, et donc essentiellement réaliser une opération de segmentation.

3 Segmentation

Variation totale jointe ou couplée – Nous proposons ici d'étudier et comparer deux estimations construites en ajoutant au terme d'attache aux données Φ dans (3) différentes formes de pénalisations que nous nommerons *jointe*, Ψ_J et *couplée*, Ψ_C :

$$\left(\hat{\mathbf{v}}^{J/C}, \hat{\mathbf{h}}^{J/C} \right) = \arg \min_{\mathbf{v}, \mathbf{h}} \Phi(\mathbf{v}, \mathbf{h}; \mathcal{L}) + \lambda \Psi_{J/C}(\mathbf{v}, \mathbf{h}; \alpha) \quad (4)$$

où les pénalisations *jointe* et *couplée* s'écrivent :

$$\Psi_J(\mathbf{v}, \mathbf{h}) := \lambda (\|\mathbf{D}\mathbf{v}\|_{2,1} + \alpha \|\mathbf{D}\mathbf{h}\|_{2,1}),$$

$$\Psi_C(\mathbf{v}, \mathbf{h}) := \lambda \|\|\mathbf{D}\mathbf{v}, \alpha \mathbf{D}\mathbf{h}\|_{2,1}.$$

avec $\mathbf{D} : \mathbb{R}^{|\Omega|} \rightarrow \mathbb{R}^{2 \times |\Omega|}$ un opérateur de différences discrètes :

$$(\mathbf{D}\mathbf{h})_{\underline{n}} := (h_{n_1, n_2+1} - h_{n_1, n_2}, \quad h_{n_1+1, n_2} - h_{n_1, n_2})^\top$$

et où la norme mixte $\|\cdot\|_{2,1}$ favorisant la parcimonie d'un vecteur $\mathbf{z} = [z_1, \dots, z_I]$ s'écrit

$$\|\mathbf{z}\|_{2,1} := \sum_{n_1=1}^{N_1-1} \sum_{n_2=1}^{N_2-1} \sqrt{\sum_{i=1}^I (z_i)_{n_1, n_2}^2}.$$

La pénalisation Ψ_J favorise ainsi la parcimonie des gradients de \mathbf{v} et \mathbf{h} , indépendamment l'un de l'autre, tandis que Ψ_C force une parcimonie couplée (les changements de puissance et régularité sont colocalisés spatialement).

Résolution algorithmique – La difficulté pour résoudre le problème de minimisation (4) réside dans la non-différentiabilité du terme de pénalisation $\Psi_{J/C}$. Il est donc nécessaire de faire appel à un schéma de descente proximal exploitant la forte convexité du terme d'attache aux données $\Phi(\cdot, \cdot; \mathcal{L})$ pour envisager l'analyse d'images de grande taille. Dans ce travail, nous adaptons l'algorithme primal-dual de [9], exploitant la μ -forte convexité ($\mu > 0$) pour la minimisation de (4). La suite $(\mathbf{v}^{[t]}, \mathbf{h}^{[t]})_{t \in \mathbb{N}}$ produite par l'Algorithme 1 converge vers le minimiseur de (4). Enfin, le seuillage proposé dans [10], permet d'obtenir une segmentation en deux régions à partir de $\hat{\mathbf{h}}^{J/C}$.

Algorithm 1: Primal-dual accéléré joint et couplé

Initialisation : Fixer $\alpha > 0$ et $\lambda > 0$,

$$\mathbf{v}^{[0]}, \mathbf{h}^{[0]} \in \mathbb{R}^{|\Omega|}; \quad \mathbf{u}^{[0]} = \bar{\mathbf{u}}^{[0]} = \mathbf{D}\mathbf{v}^{[0]}, \quad \boldsymbol{\ell}^{[0]} = \bar{\boldsymbol{\ell}}^{[0]} = \mathbf{D}\mathbf{h}^{[0]};$$

Fixer (δ_0, ν_0) t. q. : *Cas jointe* $\delta_0 \nu_0 \|\mathbf{D}\|^2 < 1$,

$$\textit{Cas couplé} \quad \delta_0 \nu_0 \max(1, \alpha) \|\mathbf{D}\|^2 < 1.$$

for $t \in \mathbb{N}^*$ **do**

Mise à jour de la variable primale :

$$\begin{pmatrix} \mathbf{v}^{[t+1]} \\ \mathbf{h}^{[t+1]} \end{pmatrix} = \text{prox}_{\delta_t \Phi} \left(\begin{pmatrix} \mathbf{v}^{[t]} \\ \mathbf{h}^{[t]} \end{pmatrix} - \delta_t \begin{pmatrix} \mathbf{D}^* \bar{\mathbf{u}}^{[t]} \\ \mathbf{D}^* \bar{\boldsymbol{\ell}}^{[t]} \end{pmatrix} \right)$$

Mise à jour de la variable duale :

$$\textit{Joint} \quad \mathbf{u}^{[t+1]} = \text{prox}_{\nu_t (\lambda \|\cdot\|_{2,1})^*} (\mathbf{u}^{[t]} + \nu_t \mathbf{D}\mathbf{v}^{[t]})$$

$$\boldsymbol{\ell}^{[t+1]} = \text{prox}_{\nu_t (\lambda \alpha \|\cdot\|_{2,1})^*} (\boldsymbol{\ell}^{[t]} + \nu_t \mathbf{D}\mathbf{h}^{[t]})$$

$$\textit{Couplé} \quad \begin{pmatrix} \mathbf{u}^{[t+1]} \\ \boldsymbol{\ell}^{[t+1]} \end{pmatrix} = \text{prox}_{\nu_t (\lambda \|\cdot\|_{2,1})^*} \left(\begin{pmatrix} \mathbf{u}^{[t]} + \nu_t \mathbf{D}\mathbf{v}^{[t]} \\ \boldsymbol{\ell}^{[t]} + \nu_t \alpha \mathbf{D}\mathbf{h}^{[t]} \end{pmatrix} \right)$$

Mise à jour des pas de descente :

$$\vartheta_t = (1 + 2\mu\delta_t)^{-1/2}, \quad \delta_{k+1} = \vartheta_t \delta_t, \quad \nu_{k+1} = \nu_t / \vartheta_t$$

Mise à jour de la variable auxiliaire :

$$\begin{pmatrix} \bar{\mathbf{u}}^{[t+1]} \\ \bar{\boldsymbol{\ell}}^{[t+1]} \end{pmatrix} = \begin{pmatrix} \mathbf{u}^{[t+1]} \\ \boldsymbol{\ell}^{[t+1]} \end{pmatrix} + \vartheta_t \left(\begin{pmatrix} \mathbf{u}^{[t+1]} \\ \boldsymbol{\ell}^{[t+1]} \end{pmatrix} - \begin{pmatrix} \mathbf{u}^{[t]} \\ \boldsymbol{\ell}^{[t]} \end{pmatrix} \right)$$

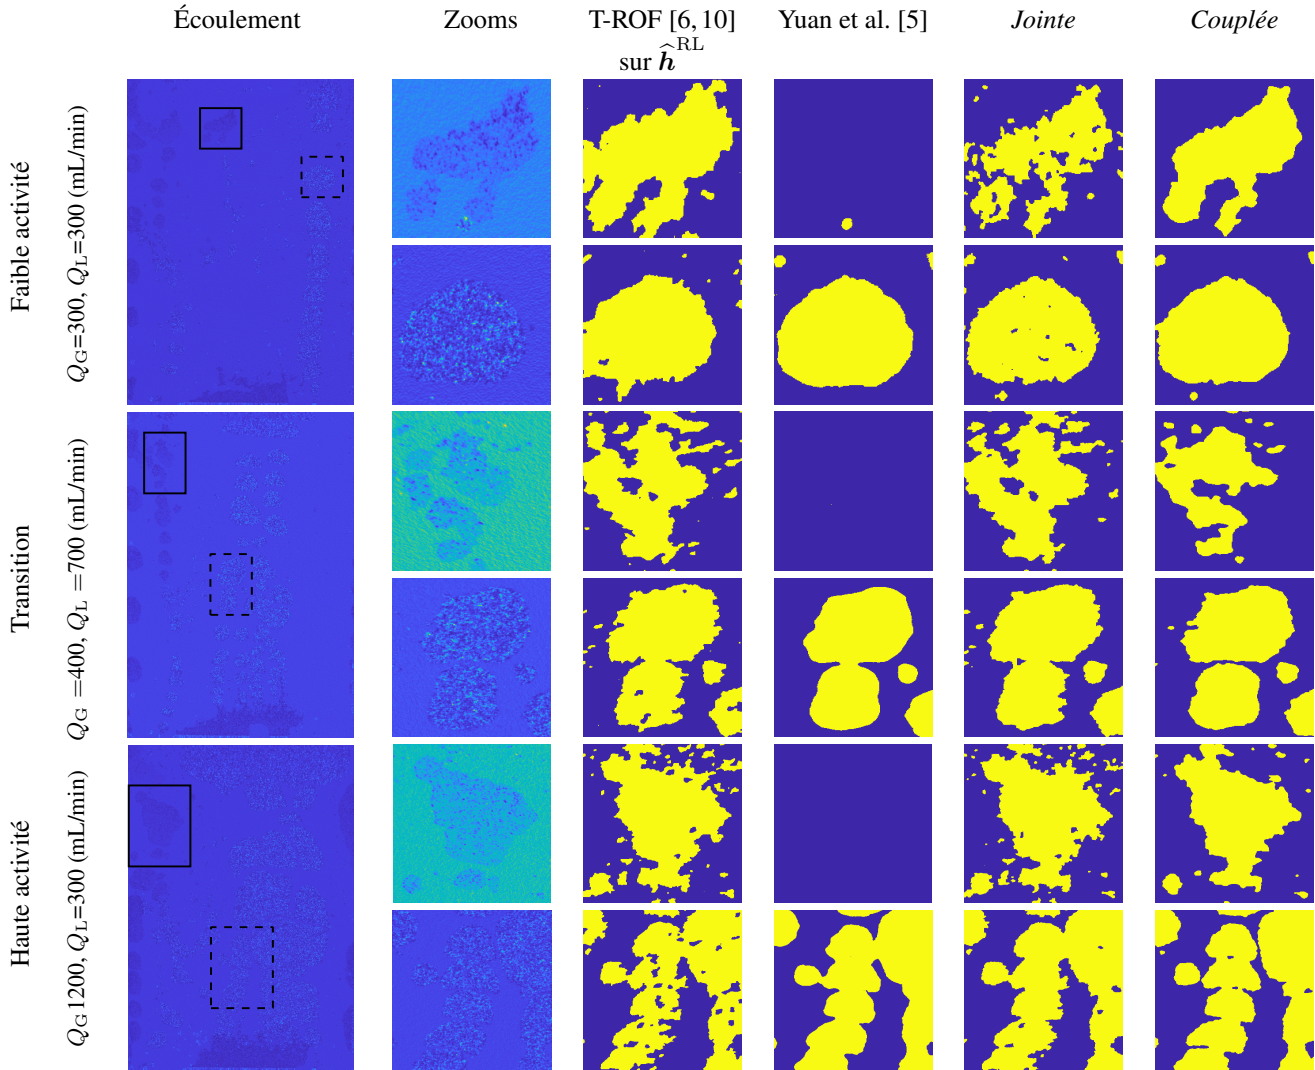


FIGURE 2 – Comparaison des différentes méthodes de segmentation pour plusieurs régimes d’écoulements. (Seuls des zooms sont affichés mais les algorithmes sont appliqués aux images entières, de 1677×1160 pixels, cf. 1^{ère} colonne.)

Méthode de l’état-de-l’art – Dans cette étude, nous comparons les résultats obtenus par les approches couplée et jointe proposées, avec ceux issus de techniques de segmentation qui constituent l’état-de-l’art :

– *ROF sur la régularité locale* : Dans [6], il est proposé d’effectuer la segmentation en deux phases : i) estimation locale de \hat{h}^{RL} par régression linéaire en chaque pixel, ii) segmentation par un débruitage par variation totale seuillé (T-ROF) [10].

– *Factorisation de matrices* – Yuan *et al.* [5] ont développé une méthode de segmentation de texture reposant essentiellement sur trois ingrédients : i) une base de filtre de Gabor, ii) le calcul d’histogrammes locaux de coefficients de Gabor, iii) la factorisation matricielle aboutissant à une segmentation.

Données synthétiques – La Fig. 1 présente la segmentation d’une texture synthétique fractale par morceaux, imitant un écoulement gaz-liquide, par différentes méthodes. Chaque région définie par le masque Fig. 1(a) correspond sur la Fig. 1(b) à une texture fractale homogène caractérisée par sa régularité locale H et sa variance locale σ : i) le fond (en noir) mo-

délise le liquide et correspond à $H_0 = 0.4$ et $\sigma_0 = 10^{-2}$, ii) des bulles sombres (en gris) sont modélisées par $H_1 = 0.9$ et $\sigma_1 = 10^{-2}$ et iii) des bulles claires (en blanc) correspondent à $H_2 = 0.9$ et $\sigma_2 = 10^{-1}$ (cf. Sec 4). On cherche à détecter les bulles de gaz (indépendamment de leur type), donc, pour un tel modèle, un changement de régularité locale. Pour des données synthétiques, la connaissance de la répartition gaz(bleu)-liquide(noir), Fig. 1(c), permet de choisir les paramètres (λ, α) optimaux, c’est-à-dire maximisant le pourcentage de pixels bien classifiés (ou score de classification) donné pour chaque méthode en Fig. 1.

Performances de segmentation – Les trois méthodes basées sur des attributs fractals, T-ROF [10] appliquée à \hat{h}^{RL} , *jointe* et *couplée* détectent les deux types de bulles claires et foncées. Néanmoins les contours des bulles sont bien plus réguliers pour la méthodes *jointe* et plus encore pour la méthode *couplée*. Ces contours plus réguliers peuvent ainsi fournir une estimation robuste du périmètre d’interface gaz-liquide, paramètre physique important pour les expérimentateurs. De même le score de clas-

sification est plus élevée pour les méthodes *jointe* et *couplée*. En comparaison, la méthode de Yuan [5] détecte très précisément les bulles claires, et leurs contours sont très réguliers mais n'est pas du tout adaptée à la détection des bulles sombres.

4 Écoulements multiphasiques

Dispositif expérimental – Les expériences d'écoulements joints de gaz et de liquide au travers d'un milieu poreux sont réalisées dans une cellule de Hele-Shaw quasi bidimensionnelle, de largeur 210 mm, de longueur 410 mm et d'épaisseur 2mm. Le milieu poreux est constitué d'une mousse solide à cellules ouvertes faite d'un alliage NiCrFeAl, avec une taille de pores caractéristique de 580 μm . Gaz et liquide sont injectés à débit constant à la base de la cellule à travers neuf injecteurs, pour l'air, et par une fente homogène, pour l'eau. Les images de l'écoulement multiphasique sont acquises par une caméra haute résolution (Basler, 2048 \times 2048) à 100 Hz. La taille des images à analyser est de 1677 \times 1160 pixels. Des exemples sont fournis en Fig. 2 (gauche) ainsi que des zooms en 2^{ème} colonne. On observe dans chaque expérience des bulles de gaz sombres ou claires selon l'épaisseur relative de leur film de lubrification sur les plaques de verre confinant la mousse.

Protocole d'étude – Plusieurs régimes d'écoulement sont explorés par les expérimentateurs, caractérisés par un débit de gaz Q_G et un débit de liquide Q_L . Nous allons étudier précisément trois images d'écoulement, représentatives de trois régimes observés lors des expériences : i) un *régime de faible activité*, à bas débits ($Q_G = Q_L = 300$ mL/min), marqué par la présence de petites bulles, ii) un *régime de transition*, à débits moyens ($Q_G = 400$ mL/min, $Q_L = 700$ mL/min) dans lequel on observe à la fois des petites bulles et de plus grosses bulles formées par coalescence, iii) un *régime de haute activité*, à haut débits ($Q_G = 1200$ mL/min, $Q_L = 300$ mL/min), fortement dominé par les grosses bulles de gaz.

Données – Pour chaque débit, un enregistrement vidéo est disponible, composant une série temporelle d'images texturées (cf. Fig. 2, 1^{ère} et 2^{ème} col.) dont les caractéristiques varient peu d'une image à l'autre au sein d'une même série.

Protocole d'analyse – Le réglage des paramètres optimaux se fait en deux temps : i) on applique les méthodes *jointe* et *couplée* en faisant varier les paramètres autour d'une valeur empirique, ii) les expérimentateurs valident les résultats de segmentation obtenus et déterminent les paramètres optimaux pour chaque méthode sur la base, d'une part, de la physique du problème, d'autre part des paramètres physiques connus (comme le volume de gaz injecté). En ce sens, les résultats présentés en Fig. 2 correspondent à la segmentation de meilleure qualité obtenue pour chaque méthode.

Discussion sur la qualité des segmentations – De même que pour les textures synthétiques les méthodes basées sur le modèle de texture fractale, T-ROF sur \hat{h}^{RL} (Fig.2, 3^{ème} col.), *jointe*, (Fig.2, 5^{ème} col.), et *couplée*, (Fig.2, 6^{ème} col.), détectent, avec la même acuité, les deux types de bulles observées. Néanmoins, on constate un gain significatif dans la régularité des contours

lorsqu'on passe de T-ROF, à la segmentation *jointe* et également entre la segmentation *jointe* et la segmentation *couplée*. Ainsi la méthode *couplée*, tout en fournissant des contours réguliers, détecte les petites bulles présentes mais sans générer les artefacts nombreux pour la méthode T-ROF, et plus rares (mais présents) dans la segmentation *jointe*.

La méthode de Yuan [5], (Fig.2, 4^{ème} col.), si elle ne génère aucun artefact et fournit des contours très réguliers, s'avère cependant aveugle aux bulles sombres observées.

5 Conclusion

Sur les données synthétiques comme sur celles d'écoulements multiphasiques, la méthode *couplée* fournit une segmentation de qualité entre liquide et bulles de gaz. Elle détecte à la fois les bulles claires et foncées, de toutes tailles, sans distinction, et cela sans générer d'artefacts. De plus les frontières gaz-liquide sont suffisamment régulières pour envisager une estimation robuste du périmètre d'interface gaz-liquide. Or, dans une expérience bi-dimensionnelle, ce périmètre, multiplié par l'épaisseur de la cellule, donne une estimation de la surface de contact entre le gaz et le liquide, paramètre physique crucial par exemple dans les problèmes de catalyse. Par la suite, nous explorerons la possibilité de fixer automatiquement les paramètres de régularisation et ainsi proposer une procédure complètement non-supervisée.

Références

- [1] G. Varas, G. Ramos, J.-C. Géminard, and V. Vidal, "Flow and fracture in water-saturated, unconstrained granular beds," *Frontiers in Physics*, vol. 3, pp. 44, 2015.
- [2] L. Najman, M. Couprie, and G. Bertrand, "Watersheds, mosaics, and the emergence paradigm," *Discrete Applied Mathematics*, vol. 147, no. 2-3, pp. 301–324, 2005.
- [3] T. F. Chan and L. A. Vese, "Active contours without edges," *IEEE Transactions on Image Processing*, vol. 10, no. 2, pp. 266–277, 2001.
- [4] S. Ray and R. H. Turi, "Determination of number of clusters in k-means clustering and application in colour image segmentation," in *Proceedings of the 4th international conference on advances in pattern recognition and digital techniques*. Calcutta, India, 1999, pp. 137–143.
- [5] J. Yuan, D. Wang, and A. M. Cheriyyadat, "Factorization-based texture segmentation," *IEEE Transactions on Image Processing*, vol. 24, no. 11, pp. 3488–3497, Nov. 2015.
- [6] N. Pustelnik, H. Wendt, P. Abry, and N. Dobigeon, "Combining local regularity estimation and total variation optimization for scale-free texture segmentation," *IEEE Transactions on Computational Imaging*, vol. 2, no. 4, pp. 468–479, 2016.
- [7] B. Pascal, N. Pustelnik, P. Abry, M. Serres, and V. Vidal, "Joint estimation of local variance and local regularity for texture segmentation. application to multiphase flow characterization," in *2018 25th IEEE International Conference on Image Processing (ICIP)*, Athens, Greece, 2018, IEEE, pp. 2092–2096.
- [8] H. Wendt, S. G. Roux, P. Abry, and S. Jaffard, "Wavelet leaders and bootstrap for multifractal analysis of images," *Signal Proces.*, vol. 89, no. 6, pp. 1100–1114, 2009.
- [9] A. Chambolle and T. Pock, "A first-order primal-dual algorithm for convex problems with applications to imaging," *Journal of Mathematical Imaging and Vision*, vol. 40, no. 1, pp. 120–145, 2011.
- [10] Xiaohao Cai and Gabriele Steidl, "Multiclass segmentation by iterated rof thresholding," in *International Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition*. Springer, 2013, pp. 237–250.