

# Segmentation d'images de microscope électronique à balayage pour l'estimation de l'encrassement des générateurs de vapeur

Vincent LE GUEN, Nicolas PAUL

EDF R&D

6 quai Watier, 78401 Chatou, France

vincent.le-guen@edf.fr, nicolas.paul@edf.fr

**Résumé** – On s'intéresse ici à l'estimation de l'encrassement des tubes des générateurs de vapeur d'une centrale nucléaire. Plus particulièrement, cet article propose un algorithme de segmentation automatique pour séparer les cristaux du fond dans des images issues d'un Microscope Electronique à Balayage. Les difficultés proviennent de la forte hétérogénéité des images en termes de contraste et de tailles des cristaux. La chaîne de traitement comporte un prétraitement d'homogénéisation du fond, une étape de segmentation mean-shift et une étape de classification non supervisée avec contraintes spatiales.

**Abstract** – We are interested in estimating the fouling rate of steam generator tubes in nuclear power plants. This article proposes an automatic segmentation algorithm to separate crystals from background in Scanning Electron Microscope images. The challenge arises from the huge heterogeneity of our image dataset (different contrast conditions, crystal sizes and densities). The pipeline encompasses a background-correction preprocessing, a meanshift segmentation and a spatially-constrained clustering step.

## 1 Introduction

Dans les Réacteurs à Eau Pressurisée (REP), les générateurs de vapeur (GV) s'encrassent au fil du temps par dépôts de particules charriées par le circuit secondaire. Il est crucial pour EDF de comprendre ce phénomène qui diminue les performances thermiques et favorise la corrosion sous contrainte.

En complément à la simulation numérique, les dépôts de cristaux de magnétite sont reproduits sur une boucle d'essais à EDF R&D sous les conditions de température et pression REP. Les tubes GV sont ensuite analysés avec un Microscope Electronique à Balayage (MEB). La segmentation des images obtenues fournit le taux d'encrassement expérimental.

Différentes conditions expérimentales ont été testées, ce qui donne un jeu de données hétérogène : images avec faible/fort encrassement, différentes échelles de cristaux, différentes conditions de contraste. L'objectif est de segmenter toutes ces images avec un unique algorithme robuste.

La segmentation d'objets dans des images est un sujet très documenté dans la littérature. Pour des images en niveaux de gris, la méthode la plus simple est le seuillage de l'histogramme pour séparer chaque classe. Des méthodes adaptatives peuvent calculer un seuil différent selon la position dans l'image [1].

De l'information spatiale peut être ajoutée grâce à la matrice de co-occurrence ou par les champs de Markov qui introduisent une dépendance probabiliste entre pixels voisins (voir [2] avec un exemple de segmentation d'IRM de cerveau).

Une technique très populaire dans ce domaine est la morphologie mathématique, qui réalise des transformations non linéaires à partir des opérations basiques d'érosion et de dilata-




FIGURE 1 – Etapes de l'algorithme : (a) image originale, (b) correction de la non-homogénéité du fond, (c) détection de modes mean-shift, (d) fusion des modes, (e) classification.

tion sur un élément structurant. En particulier, l'algorithme de

"ligne de séparation des eaux" et ses variantes a de nombreuses applications : segmentation de granulats dans des images de béton [3], granulométrie des roches [4], segmentation d'images biomédicales [5]. Néanmoins, ces méthodes sont très dépendantes de la géométrie de l'élément structurant et supposent une certaine homogénéité des formes et des intensités. Pour des formes et des distributions de niveaux de gris plus complexes, des méthodes hybrides combinent plusieurs indices. Par exemple dans [6], une décision multi-critères est faite sur la texture, l'intensité et les contours pour segmenter des rochers pour un robot d'exploration de Mars. Les méthodes d'apprentissage statistique sont également très étudiées pour la segmentation de classes d'objets ([7], [8]).

## 2 Algorithme proposé

### 2.1 Prétraitement

Pour des raisons d'usage, le matériau inspecté est souvent composé de bandes parallèles alternativement claires et sombres, qui peuvent induire en erreur les algorithmes de segmentation basés sur les niveaux de gris. A une rotation de l'image près, on considère ces bandes horizontales. La variation d'intensité du fond est alors estimée par Analyse en Composantes Principales (ACP) sur les colonnes de l'image. Pour une image de taille  $N \times M$ , on construit la matrice de covariance empirique des colonnes  $C = \frac{1}{M} \sum_{j=1}^M x_j x_j^T$  où  $(x_j)_{1 \leq j \leq M} \in \mathbb{R}^N$  sont les colonnes (centrées) de l'image. La composante principale (vecteur propre de  $C$  associé à la plus grande valeur propre) représente le mode de plus grande variabilité verticale dans l'image (voir Figure 2). On la retranche à chaque colonne de l'image pour correction.




FIGURE 2 – Gauche : composante principale selon l'axe vertical pour Fig 1 (a). Droite : variation de luminosité correspondante que l'on soustrait à l'image pour obtenir Fig 1 (b).

## 2.2 Segmentation mean-shift

### 2.2.1 Détection de modes

Mean-shift est un algorithme non paramétrique basé sur l'estimation à noyau pour rechercher les maxima locaux d'une densité de probabilité. Proposé initialement par Fukunaga et Hostetler [9], il a été ensuite appliqué à la segmentation d'images

par Comaniciu et Meer [10].

On considère l'image comme un ensemble de points échantillonnés selon une certaine loi de probabilité  $f$  dans un espace tri-dimensionnel (composé des coordonnées spatiales et de l'intensité des niveaux de gris). On cherche à identifier les modes de la loi  $f$ . Soient  $n$  points  $x_1, \dots, x_n \in \mathbb{R}^3$ , l'estimateur à noyau de la densité (ou estimateur de Parzen) de noyau  $K$ , de paramètres d'échelle  $H = \text{diag}(h_s, h_s, h_i)$  ( $h_s$  paramètre spatial,  $h_i$  paramètre d'intensité), calculé au point  $x$  s'écrit :

$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K((x - x_i)^T H^{-1}(x - x_i)). \quad (1)$$

L'estimateur du gradient de la densité s'écrit

$$\nabla \hat{f}(x) = \frac{2H^{-1}}{n} \left[ \sum_{i=1}^n K'((x - x_i)^T H^{-1}(x - x_i)) \right] \times \underbrace{\left[ x - \frac{\sum_{i=1}^n x_i K'((x - x_i)^T H^{-1}(x - x_i))}{\sum_{i=1}^n K'((x - x_i)^T H^{-1}(x - x_i))} \right]}_{\vec{m}(x)}. \quad (2)$$

Le premier terme est positif et le second est défini comme le vecteur mean-shift  $\vec{m}(x)$ . En comparant (1) et (2), on remarque que

$$\vec{m}(x) \propto \frac{\nabla \hat{f}(x)}{\hat{f}(x)}, \quad (3)$$

où  $\hat{f}$  est l'estimateur de densité avec le noyau  $K'$ . Le vecteur mean-shift pointe donc dans la direction de plus forte hausse de la densité. La procédure mean-shift complète consiste à initialiser le noyau en chaque pixel dans l'espace de représentation, à le translater du vecteur mean-shift et à itérer jusqu'à convergence. Les modes regroupent alors tous les pixels ayant convergé vers le même point stationnaire. C'est une méthode de montée de gradient adaptative : les pas sont plus grands dans les régions de faible densité et plus fins près d'un maximum local. Cette étape est illustrée sur la Figure 1 (c).

### 2.2.2 Fusion des modes

L'image résultante a encore un grand nombre de modes. De plus, certains modes de fond (MF) sont plus clairs que certains modes de cristal (MC) dans d'autres régions de l'image. Il est donc nécessaire de fusionner entre eux les modes du fond. Une méthode simple consisterait à fusionner transitivement tous les modes dont les différences d'intensité sont en-dessous d'un seuil  $T$  (critère 1). Toutefois, un MC peut être fusionné avec le fond s'il existe un chemin avec un faible dégradé d'intensité qui les connecte (exemple des chemins rouges sur la Figure 3).

Pour éviter ce problème, on applique un détecteur de contours sur l'image originale et on interdit comme condition additionnelle la fusion de modes qui sont séparés par un contour (critère 2). Cela permet de segmenter des cristaux qui ont un faible contraste par rapport au fond mais des contours marqués. La Figure 3 montre que le critère 2 permet de bien séparer ces cristaux, et crée un fond homogène.




FIGURE 3 – Première ligne : image originale et résultat de mean-shift+fusion avec le critère 1 (2 dégradés qui mènent à une fusion cristal-fond sont représentés en rouge). Deuxième ligne : la carte des contours et le résultat avec le critère 2.

Nous avons utilisé pour mean-shift l’implémentation EDISON (Edge Detection and Image SegmentatiON) [11], avec le détecteur de contours présenté dans [12].

### 2.3 Classification

La dernière étape consiste à binariser l’image entre cristaux et fond. On s’intéresse à la fonctionnelle suivante

$$J(\mu, z) = \sum_{i=1}^N \sum_{k=1}^K z_{ik} \| I(x_i) - \mu_k \|^2 + \frac{\alpha}{N_R} \sum_{i=1}^N \sum_{k=1}^K z_{ik} \left( \sum_{x_r \in N_i} \| I(x_r) - \mu_k \|^2 \right) \quad (4)$$

où  $(I(x_i))_{1 \leq i \leq N}$  sont les intensités des pixels,  $(\mu_k)_{1 \leq k \leq K}$  sont les centres des clusters,  $z$  est la matrice de partition ( $z_{ik} = 1$  si le pixel  $i$  est affecté au cluster  $k$ , et 0 sinon),  $N_i$  est l’ensemble des voisins du pixel  $i$  et  $N_R$  la taille du voisinage.

Le premier terme est la fonctionnelle classique du K-Means et le second terme de consistance spatiale permet de récupérer des pixels sombres de cristaux, pourvu qu’ils aient des voisins classés positivement.

Comme les cristaux octaédriques de magnétite se projettent sur le plan de l’image avec en général 2 niveaux de gris différents selon l’orientation des faces (Figure 3 droite), nous avons fixé un nombre de classes  $K = 3$  (1 classe pour le fond, 2 classes pour les cristaux).

Un cas défavorable se produit lorsque des parties très sombres du fond (qu’on appellera par la suite biais locaux) attirent à elles une classe entière (Figure 4), classant ainsi tout le reste de l’image (y compris le fond) comme du cristal. Pour cette raison, on introduit un terme de biais  $\beta_i : y_i = I(x_i) + \beta_i, i = 1, \dots, N$ ,  $y_i$  étant l’observation et  $I(x_i)$  la vraie valeur (inconnue) du pixel. Cette technique est inspirée de la littérature d’image-rie par résonance magnétique [13] pour gérer ce type de non-




FIGURE 4 – Première ligne à gauche, image originale avec les biais locaux pointés par les flèches ; à droite, histogramme de l’image après mean-shift+fusion et les classes obtenues (on remarque que les biais locaux attirent une classe entière, rendant la plus grande partie du fond mal classée). Deuxième ligne à gauche, histogramme après convergence du K-means spatial avec correction de biais. A droite, résultat de segmentation.

homogénéités spatiales. La fonctionnelle (4) devient alors

$$J(\mu, z, \beta) = \sum_{i=1}^N \sum_{k=1}^K z_{ik} \| y_i - \beta_i - \mu_k \|^2 + \frac{\alpha}{N_R} \sum_{i=1}^N \sum_{k=1}^K z_{ik} \left( \sum_{x_r \in N_i} \| y_r - \beta_r - \mu_k \|^2 \right) \quad (5)$$

La fonctionnelle (5) est minimisée alternativement coordonnée par coordonnée, en partant de plusieurs initialisations et en gardant la solution de plus faible énergie. Après convergence, l’histogramme avec ses 3 classes et l’image résultat sont présentés sur la Figure 4. Le biais  $\beta$  capture les écarts à une image idéale à 3 classes. Autrement dit, le K-Means spatial avec correction de biais cherche à former une image à K classes qui minimise la variance intra-classe et favorise la consistance spatiale. Cette méthode a permis d’estimer les biais locaux et segmenter convenablement l’image comme on le voit sur la Figure 4. Cela renforce la robustesse de notre méthode.

## 3 Résultats expérimentaux

Nous avons appliqué la méthode sur notre vaste jeu d’images acquises à EDF R&D (Figure 5). Le seul paramètre laissé libre à l’opérateur est le paramètre spatial  $h_s$ . Pour chaque image de (a) à (d), l’opérateur choisit la valeur de  $h_s$  qui donne visuellement le meilleur résultat. Sans vérité terrain, le taux d’encrassement est difficile à valider autrement que visuellement. Toutefois, une segmentation manuelle de l’image (d) a été réalisée par un expert, et la différence avec le taux de notre algorithme est très faible, de l’ordre de 1 %.




FIGURE 5 – Résultats expérimentaux sur les images de tubes de générateurs de vapeur avec les taux d’encrassement associés.

## 4 Conclusion et perspectives

Nous avons présenté une méthode d’estimation du taux d’encrassement des générateurs de vapeur par segmentation d’images MEB. Elle est composée de 3 principales étapes : prétraitements, segmentation mean-shift et classification. Notre algorithme permet de gérer la forte variabilité des images d’entrée (contraste, nombre et taille des cristaux) et les résultats sont satisfaisants sur l’intégralité de notre jeu de données d’images MEB. Nos futurs travaux nous mèneront à faire une comparaison détaillée avec les méthodes de morphologie mathématique.

## Remerciements

Nous tenons à remercier Alain Ungar, Chantal Hervouet (EDF R&D, département MFEE) et Michel Mahe (département MMC) qui ont réalisé les expériences et fourni les images MEB.

## Références

- [1] M. Sezgin and S. Bulent, “Survey over image thresholding techniques and quantitative performance evaluation,” *Journal of Electronic imaging*, vol. 13, no. 1, pp. 146–168, 2004.
- [2] Y. Zhang, M. Brady, and S. Smith, “Segmentation of brain MR images through a hidden markov random field model and the expectation-maximization algorithm,” *IEEE Transactions on Medical Imaging*, vol. 20, no. 1, pp. 45–57, 2001.
- [3] J. Escoda, *Modélisation morphologique et micromécanique 3D de matériaux cimentaires*, Ph.D. thesis, École nationale supérieure des mines de Paris, 2012.
- [4] S. Mkwelo, G. De Jager, and F. Nicolls, “Watershed-based segmentation of rock scenes and proximity-based classification of watershed regions under uncontrolled lighting conditions,” *Pattern Recognition Association of South Africa (PRASA)*, pp. 107–112, 2003.
- [5] E. Martínez, X. Jové, F. de la Torre, and E. Santamaría, “Unsupervised morphological segmentation of objects in contact,” *GRETSI, Groupe d’Etudes du Traitement du Signal et des Images*, 1997.
- [6] Y. Song and J. Shan, “Automated rock segmentation for mars exploration rover imagery,” *Lunar and Planetary Science Conference XXXIX, Houston*, 2008.
- [7] V. Dinh-Phong and H. Sahbi, “Transductive inference amp ; kernel design for object class segmentation,” in *19th IEEE International Conference on Image Processing (ICIP), 2012*, Sept 2012, pp. 2173–2176.
- [8] M. Scalzo and S. Velipasalar, “Autonomous multi-scale object detection with hough forests,” in *IEEE International Conference on Image Processing (ICIP), 2014*, 2014.
- [9] K. Fukunaga and L. Hostetler, “The estimation of the gradient of a density function, with applications in pattern recognition,” *IEEE Transactions on Information Theory*, vol. 21, no. 1, pp. 32–40, 1975.
- [10] D. Comaniciu and P. Meer, “Mean shift : A robust approach toward feature space analysis,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 5, pp. 603–619, 2002.
- [11] C.M. Christoudias, B. Georgescu, and P. Meer, “Synergism in low level vision,” *16th IEEE International Conference on Pattern Recognition*, , no. 4, pp. 150–155, 2002.
- [12] P. Meer and B. Georgescu, “Edge detection with embedded confidence,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, no. 12, pp. 1351–1365, 2001.
- [13] M.N. Ahmed, S.M. Yamany, N.Mohamed, A.A.Farag, and T.Moriarty, “A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data,” *IEEE Transactions on Medical Imaging*, vol. 21, no. 3, pp. 193–199, 2002.