

Décomposition en superpixels via l'utilisation de chemin linéaire

Rémi GIRAUD^{1,2}, Vinh-Thong TA^{1,3}, Nicolas PAPADAKIS²

¹Univ. Bordeaux, LaBRI, CNRS, UMR 5800, F-33400 Talence, France

²Univ. Bordeaux, IMB, CNRS, UMR 5251, F-33400 Talence, France

³Bordeaux INP, LaBRI, UMR 5800, F-33405 Talence, France

{remi.giraud, vinh-thong.ta}@labri.fr, nicolas.papadakis@math.u-bordeaux.fr

Résumé – Pour la plupart des méthodes de décomposition en superpixels, un compromis est calculé entre : 1) la régularité de la décomposition, 2) l'homogénéité couleur des superpixels et 3) l'adhérence aux contours de l'image. Dans ce papier, nous proposons une méthode rapide de décomposition qui vise à améliorer conjointement ces aspects en utilisant une information couleur et contour le long du chemin linéaire entre chaque pixel et le barycentre du superpixel qui le contient. La méthode proposée produit des superpixels réguliers qui adhèrent aux contours, et obtient des résultats supérieurs à ceux des méthodes de l'état-de-l'art sur les métriques superpixel et de détection de contours.

Abstract – For most superpixel methods, a trade-off is computed between 1) the regularity of the decomposition, 2) the color homogeneity of the superpixels and 3) the adherence to image contours. In this paper, we propose a fast decomposition method that aims to jointly enforce these aspects and compute superpixels using color and contour features along the linear path between each pixel and the barycenter of its related superpixel. The proposed framework produces regular superpixels that adhere to the contours, and obtains results that outperform the ones of state-of-the-art methods on superpixel and contour detection metrics.

1 Introduction

Afin de diminuer le temps de calcul et d'augmenter la précision de nombreuses applications de traitement d'images, notamment de segmentation, les méthodes de décomposition en superpixels ont été proposées. Ces méthodes regroupent les pixels en zones homogènes en essayant de respecter les contours de l'image, réduisant ainsi considérablement le nombre d'éléments à traiter, tout en préservant l'information géométrique, perdue avec les approches multi-résolution.

Les méthodes de superpixels peuvent se diviser en deux catégories qui produisent des décompositions soit irrégulières soit régulières. Avec les méthodes irrégulières, les superpixels peuvent être étirés, avec des tailles très différentes, avoir des frontières bruitées et sont plus susceptibles de se superposer avec plusieurs objets de l'image. À l'inverse, les méthodes régulières produisent des superpixels de tailles équivalentes, et permettent de calculer des descripteurs plus robustes. Pour la majorité des méthodes, un compromis est calculé entre : régularité de la décomposition, homogénéité couleur et adhérence aux contours. Bien que des performances élevées de détection de contours peuvent être obtenues avec des méthodes irrégulières comme [14], il est crucial pour la reconnaissance d'objets [6] ou le suivi dans des vidéos [17], d'utiliser des décompositions régulières, plus cohérentes d'une image à l'autre.

Les méthodes régulières sont généralement basées sur l'élargissement de régions, par exemple la méthode Turbopixels [7] ou basées sur des graphes, par exemple Quick shift [16]. Plus récemment, l'algorithme SLIC a été proposé [1], suivi d'extensions, par exemple [19, 4]. Cette méthode produit une décomposition régulière plus rapidement que des approches basées-graphes [16], et obtient des performances état-de-l'art. Cependant, un paramètre étant fixé pour assurer la régularité, SLIC peut échouer à adhérer localement aux contours de l'image.

Plusieurs travaux ont tenté d'utiliser une information de contour, par exemple [12], qui contraint la décomposition par un maillage régulier issu d'une carte de contours. Les superpixels ont alors des tailles régulières mais des formes irrégulières [12]. Dans [8, 19], des cartes de poids pré-calculées depuis les gradients de l'image contraignent localement la forme des superpixels. Enfin, des méthodes permettent de calculer des régions depuis une carte de contours, par exemple [2], mais ne contrôlent ni leur forme ni leur nombre, et ne peuvent donc pas être considérées comme des méthodes superpixels.

Contributions. Dans ce travail, nous proposons la méthode SCALP (pour Superpixels with Contour Adherence using Linear Path). Le chemin linéaire au barycentre d'un superpixel est défini, et la distance calculée lors de la décomposition considère l'information couleur et contour sur ce chemin. Notre méthode améliore ainsi conjointement les trois propriétés des superpixels : homogénéité, régularité et adhérence aux contours. Enfin, SCALP obtient des résultats supérieurs à ceux de l'état-de-l'art sur la base Berkeley Segmentation Dataset (BSD) [9].

Ce travail a bénéficié d'un support financier de l'état Français, via l'Agence Nationale de la Recherche (ANR) dans le cadre du projet GOTMI (ANR-16-CE33-0010-01) et du programme d'Investissements d'Excellence IdEx Bordeaux (ANR-10-IDEX-03-02) avec le Cluster d'excellence CPU.




FIGURE 1 – La méthode SCALP. La décomposition est calculée selon l’information couleur sur le chemin au barycentre du superpixel. Une carte de contours (flèches pointillées) peut être utilisée pour améliorer le respect des contours de l’image

2 La méthode SCALP

2.1 Algorithme de groupement itératif

L’algorithme SLIC (pour Simple Linear Iterative Clustering) [1] est une méthode qui, par défaut, ne requiert que le nombre K de superpixels à générer. La décomposition part d’une grille régulière, composée de blocs de taille $r \times r$, avec $r = \sqrt{N/K}$, pour une image de N pixels. Chaque superpixel S_k est représenté par un descripteur C_k , qui contient l’information couleur (dans l’espace CIELab) et spatiale (barycentre) moyenne des pixels $p \in S_k$, tel que $C_k = [(l_k, a_k, b_k), (x_k, y_k)]$.

Pour chaque superpixel, un groupement itératif des pixels $p = [(l_p, a_p, b_p), (x_p, y_p)]$, dans une zone de $(2r+1) \times (2r+1)$ pixels, centrée sur (x_k, y_k) , est alors effectué. Une distance couleur $d_c(p, C_k) = (l_p - l_k)^2 + (a_p - a_k)^2 + (b_p - b_k)^2$ et spatiale $d_s(p, C_k) = \frac{m^2}{r^2} ((x_p - x_k)^2 + (y_p - y_k)^2)$, sont calculées, et le pixel p est assigné au superpixel S_k qui minimise la somme de ces distances, avec m le paramètre de régularité.

Cette méthode permet d’obtenir des résultats de segmentation proches de ceux de l’état-de-l’art. Cependant, puisque seule la couleur du pixel p est considérée et qu’un paramètre contraint la forme des superpixels, SLIC peut échouer à grouper les pixels de couleurs homogènes tout en adhérant aux contours. Avec l’introduction du chemin linéaire au barycentre du superpixel, SCALP calcule une distance couleur précise qui améliore l’homogénéité couleur et la régularité des superpixels. Ce chemin permet également de considérer une information de contour pour assurer le respect des objets de l’image, améliorant ainsi simultanément les trois aspects de la décomposition. La Figure 1 résume la méthode proposée SCALP.

2.2 Chemin linéaire

On définit le chemin \mathbf{P}_p^k , contenant les pixels entre la position $X_p = (x_p, y_p)$ d’un pixel p et le barycentre $X_k = (x_k, y_k)$ d’un superpixel S_k . Afin de limiter le nombre de pixels dans \mathbf{P}_p^k , [3] est utilisé pour ne considérer que les pixels sur le chemin linéaire entre X_p et X_k , comme illustré dans la Figure 2. Les pixels considérés q (rouge) sont ceux qui intersectent avec le segment (flèche) entre X_p (bleu), et X_k (vert). Considérer ce chemin linéaire permet de limiter le temps de calcul et d’améliorer naturellement la régularité de la décomposition.




FIGURE 2 – Définition du chemin linéaire \mathbf{P}_p^k au barycentre du superpixel S_k pour un pixel p (voir le texte pour plus de détails)

2.3 Distance couleur au superpixel

Avec le chemin proposé, la distance couleur peut maintenant être calculée sur \mathbf{P}_p^k , l’ensemble des pixels q sur le chemin entre la position du pixel p et le barycentre du superpixel S_k :

$$d_c(p, C_k, \mathbf{P}_p^k) = \lambda d_c(p, C_k) + (1-\lambda) \frac{1}{|\mathbf{P}_p^k|} \sum_{q \in \mathbf{P}_p^k} d_c(q, C_k), \quad (1)$$

où $\lambda \in [0, 1]$ pondère l’influence de la distance couleur le long du chemin entre X_p et X_k . SCALP améliore l’homogénéité couleur, puisque pour que (1) soit faible, la couleur sur \mathbf{P}_p^k doit être proche de la couleur moyenne du superpixel.

La distance (1) empêche également l’apparition de formes irrégulières et améliore naturellement la régularité. On considère en Figure 3, un exemple de forme irrégulière pouvant survenir avec SLIC [1], dans des zones de dégradé d’intensités. Le barycentre n’est pas contenu dans le superpixel S_k , et le chemin capture des couleurs éloignées de la couleur moyenne de S_k .




FIGURE 3 – Exemple de groupement irrégulier obtenu avec SLIC [1] (à gauche) et rendu régulier avec la distance couleur sur le chemin linéaire (1) de SCALP (à droite)

2.4 Adhérence aux contours

L’homogénéité couleur et la régularité des superpixels sont améliorées par la distance couleur proposée (1). Comme présenté en introduction, contraindre la régularité des superpixels peut empêcher ces derniers de coller aux contours de l’image. Le chemin proposé permet également de considérer une carte de contours afin d’augmenter cette adhérence. Cette carte, notée \mathcal{C} , est telle que $\mathcal{C}(p) \rightarrow 1$ si un contour est détecté au pixel p , sinon 0. On propose de pondérer la distance par d_c , la valeur maximale de contours sur \mathbf{P}_p^k :

$$d_C(\mathbf{P}_p^k) = 1 + \gamma \max_{q \in \mathbf{P}_p^k} \mathcal{C}(q), \quad (2)$$

où $\gamma \geq 0$ pondère l’influence de la carte de contours sur \mathbf{P}_p^k .




FIGURE 4 – Illustration de l’itération n°1 de SCALP (à gauche) avec une information de contour (à droite). L’intensité maximale de contour sur \mathbf{P}_p^k (le pixel jaune) est considérée dans (2)

La Figure 4 illustre la sélection de l’intensité maximum le long du chemin linéaire. Lorsqu’un contour intersecte ce chemin, le terme proposé d_C permet de pénaliser l’association du pixel p au superpixel S_k . Enfin, pour assurer le respect des contours, nous multiplions ce terme aux distances couleur et spatiale pour définir la distance finale D à minimiser durant le processus itératif de groupement :

$$D(p, C_k) = \left(d_c(p, C_k, \mathbf{P}_p^k) + d_s(p, C_k) \frac{m^2}{r^2} \right) d_C(\mathbf{P}_p^k), \quad (3)$$

avec la distance spatiale d_s , calculée comme dans [1], et m le paramètre de régularité. Un m élevé force la convexité et produit des superpixels carrés pour une grille initiale régulière, quand un m faible permet une meilleure adhérence aux contours, mais produit des superpixels aux formes irrégulières.

3 Résultats

3.1 Validation

Base de données. Pour évaluer notre méthode, nous considérons la base BSD (Berkeley Segmentation Dataset) [9]. Celle-ci contient 200 images de taille 321×481 pixels avec au moins 5 segmentations manuelles fournies par image pour permettre l’évaluation des décompositions calculées.

Métriques. Pour évaluer les performances de notre méthode et se comparer à celles de l’état-de-l’art, on utilise la métrique d’évaluation standard des superpixels : l’erreur de sous-segmentation UE (pour undersegmentation error), qui mesure le nombre de pixels qui appartiennent à plusieurs objets de l’image [1]. On compare la régularité des superpixels avec la mesure de compacité C [13]. Enfin, les performances de détection de contours sont évaluées avec les courbes de précision (P) et rappel (R) [10], avec la même méthode de validation que dans [14]. On indique alors pour chaque méthode, la mesure F maximum qui calcule un compromis entre précision et rappel.

Paramètres. La méthode SCALP est implémentée avec MATLAB. Le nombre d’itérations est fixé à 5. On fixe empiriquement λ à 0,5 dans (1) et γ à 50 dans (2). Notons que lorsque $\lambda = 1$ et $\gamma = 0$, la méthode est réduite à [1]. Le paramètre de régularité m (3) est fixé à 10, comme dans [1]. Par défaut, nous utilisons une carte de contours calculée depuis [5].




FIGURE 5 – Courbes PR de SCALP pour différents paramètres de distance (à gauche) et de détection de contours (à droite)

3.2 Influence des paramètres

On mesure d’abord l’influence des paramètres de la méthode SCALP. Dans la Figure 5, on fournit les courbes PR pour différents paramètres de distance. Les distances couleur (1) et contour (2) calculées sur le chemin linéaire augmentent chacune les performances de décomposition. La méthode complète (3), c’est-à-dire avec les deux distances, fournit les meilleurs résultats et surpassent ceux de la méthode initiale SLIC [1].

On considère également dans la Figure 5 l’influence de la carte de contours. On compare les résultats obtenus avec différentes méthodes de détection : [18], [11] et [5]. Chaque information de contour dans (2) permet d’améliorer les résultats. Par la suite, nous utiliserons la détection de contours de [5].

3.3 Comparaison avec l’état-de-l’art

La méthode SCALP est comparée aux méthodes de l’état-de-l’art suivantes : Quick shift (QS) [15], SLIC [1], SEEDS [14], Waterpixels (WP) [8] et LSC [4]. Tous les résultats présentés ont été obtenus à partir des codes des auteurs avec les paramètres par défaut. Les critères quantitatifs sont calculés selon la méthode de validation décrite dans la Section 3.1.

Dans la Figure 6, on représente les courbes PR et UE pour différentes échelles de superpixels. SCALP obtient les meilleurs résultats de détection de contours avec la plus haute mesure $F(0,682)$, ainsi que les meilleurs performances d’erreur de sous-segmentation. SCALP produit donc des superpixels qui se superposent avec moins d’objets différents et surpasse notamment des méthodes récentes telles que [8] et [4].

La Table 1 reporte la mesure de compacité C [13] moyennée sur plusieurs échelles, de 6 à 600 superpixels comme dans [14]. SCALP obtient la meilleure mesure de compacité, et améliore notamment la régularité des superpixels générés par SLIC [1].

La Figure 7 montre des exemples de décomposition pour SCALP et les méthodes comparées. SCALP produit les superpixels les plus réguliers en respectant précisément les contours de l’image. Enfin, sans architecture multi-processus, SCALP décompose une image en moins de 0,4s, ce qui correspond au temps de calcul de la meilleure méthode comparée LSC [4].

TABLE 1 – Comparaison de la régularité (C) des superpixels

QS [15]	SLIC [1]	SEEDS [14]	WP [8]	LSC [4]	SCALP
0,271	0,333	0,216	0,307	0,174	0,388

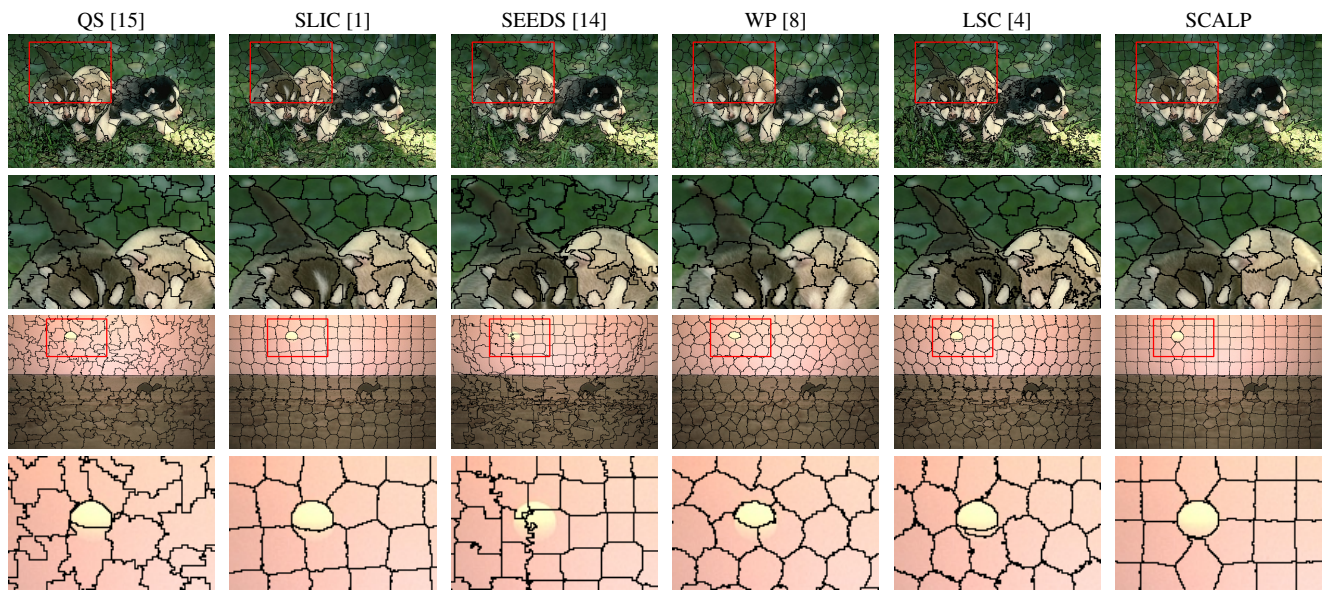


FIGURE 7 – Comparaison des décompositions générées par SCALP et les méthodes de l'état-de-l'art sur des images de la BSD




FIGURE 6 – Comparaison des résultats PR et UE de SCALP et des méthodes de l'état-de-l'art sur la BSD

4 Conclusion

Dans ce travail, nous proposons une généralisation de l'algorithme de groupement itératif de [1], en considérant une information couleur et contour le long du chemin linéaire au barycentre du superpixel. On améliore ainsi conjointement les trois aspects de la décomposition : homogénéité couleur, régularité et adhérence aux contours de l'image. SCALP obtient des performances état-de-l'art sur les métriques classiques d'évaluation des méthodes superpixels. De futurs travaux se focaliseront sur l'adaptation de SCALP aux décompositions en superpixels pour le traitement de la vidéo ou d'images 3D.

Références

[1] R. Achanta, et al. *SLIC superpixels compared to state-of-the-art superpixel methods*, PAMI, 2012.

[2] P. Arbelaez, et al. *From contours to regions: an empirical evaluation*, CVPR, 2009.

[3] J. Bresenham. *Algorithm for computer control of a digital plotter*, IBM Syst. J., 1965.

[4] J. Chen, et al. *Linear spectral clustering superpixel*, TIP, 2017.

[5] P. Dollár, et al. *Structured forests for fast edge detection*, ICCV, 2013.

[6] S. Gould, et al. *Superpixel graph label transfer with learned distance metric*, ECCV, 2014.

[7] A. Levinstein, et al. *TurboPixels: Fast superpixels using geometric flows*, PAMI, 2012.

[8] V. Machairas, et al. *Waterpixels*, TIP, 2015.

[9] D. Martin, et al. *A Database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics*, ICCV, 2001.

[10] D. Martin, et al. *Learning to detect natural image boundaries using local brightness*, PAMI, 2004.

[11] M. Maire, et al. *Using contours to detect and localize junctions in natural images*, CVPR, 2008.

[12] A. Moore, et al. *Superpixel lattices*, CVPR, 2008.

[13] A. Schick, et al. *Measuring and evaluating the compactness of superpixels*, ICPR, 2012.

[14] M. Van den Bergh, et al. *SEEDS: Superpixels extracted via energy-driven sampling*, ECCV, 2012.

[15] A. Vedaldi, et al. *Quick shift and kernel methods for mode seeking*, ECCV, 2008.

[16] O. Veksler, et al. *Superpixels and supervoxels in an energy optimization framework*, ECCV, 2010.

[17] S. Wang, et al. *Superpixel tracking*, ICCV, 2013.

[18] R. Xiaofeng, et al. *Discriminatively trained sparse code gradients for contour detection*, NIPS, 2012.

[19] Y. Zhang, et al. *A Simple algorithm of superpixel segmentation with boundary constraint*, TCSVT, 2016.