

# Généralisation du filtre de FRANGI pour l'extraction des réseaux de fissures au sein d'images d'un glissement de terrain.

## Comparaison avec une méthode d'apprentissage profond.

Louis HAUSEUX<sup>1</sup> Raphaël ANTOINE<sup>2</sup> Philippe FOUCHER<sup>3</sup> Pierre CHARBONNIER<sup>3</sup> Josiane ZERUBIA<sup>1</sup>

<sup>1</sup>Inria, Université Côte d'Azur, Sophia Antipolis France

<sup>2</sup>Cerema Normandie-Centre, Le Grand Quevilly, France

<sup>3</sup>Cerema Est, Strasbourg, France

**Résumé** – Le filtre de FRANGI est un algorithme classique en traitement d'image pour détecter les structures tubulaires (vaisseaux, fissures, *etc.*). Nous en reprenons les idées, en les généralisant afin d'obtenir une réponse non pas *pixelique*, mais en chaque *couple de pixels* voisins. Cette généralisation permet d'obtenir des informations plus précises sur le réseau de structures tubulaires, et de disposer d'un panel d'algorithmes pour graphes (pour construire un clustering hiérarchique par exemple). Nous appliquons cette nouvelle méthode à l'extraction du réseau linéique de fissures sur des images de sols argileux. La comparaison avec une méthode d'apprentissage profond couplée avec du *transfer learning* montre des résultats équivalents, voire légèrement supérieurs lorsque le "transfert" est fait avec des images similaires. Notre méthode a le grand avantage de ne nécessiter aucunes données d'apprentissage annotées. De plus, elle ne repose que sur un tout petit nombre de paramètres qui peuvent être fixés de façon *ad hoc*.

**Abstract** – FRANGI filter is a classical algorithm in image processing used to enhance tubular structures (vessels, cracks, *etc.*). We build upon the ideas of this filter by generalizing them in order to obtain, not a *pixelwise* response, but for each *pair* of neighboring pixels. This generalization allows for more precise information about the network of tubular structures. Working with graphs, it provides access to a range of graphical algorithms (*e.g.* for clustering). We apply these ideas to the extraction of the linear crack network in images of clay soils. The comparison with a deep learning method in combination with *transfer learning* shows equivalent or slightly better results when the transfer is performed with similar images (same types of soil, same lighting conditions, *etc.*). Our method has the significant advantage of not requiring annotated training data. Moreover, it relies on a very small number of parameters that can be set in an *ad hoc* manner.

## 1 Introduction

La cartographie des fissures dans les glissements de terrain est cruciale pour comprendre leur dynamique et leur évolution. Les caractéristiques géométriques de chaque fissure (orientation, taille, ramifications...) reflètent les déformations subies par le glissement. Leur distribution spatiale peut aussi mettre en évidence les zones susceptibles de s'étendre. Une détection précoce de ces fissures permet d'anticiper les effondrements et de mettre en place des mesures de sécurisation adaptées [1].

Cependant, cette cartographie s'avère complexe, car elle repose actuellement 1) sur des mesures de terrain difficiles à mettre en œuvre, notamment dans les zones inaccessibles ; 2) sur des interprétations visuelles d'images par des experts. Les méthodes automatiques, souvent fondées sur l'apprentissage profond [8, 10], se heurtent à un obstacle majeur : l'annotation des données. Ce défi est particulièrement prononcé dans notre contexte en raison de l'expertise géomorphologique requise. À titre d'exemple, l'annotation de la seule grande image  $3760 \times 2058$  utilisée pour le *transfer learning* de la méthode d'apprentissage profond (§ 3.2) a nécessité deux jours de travail d'un expert.

Dans cet article, nous proposons une approche fondée sur un filtre de FRANGI généralisé et la théorie des graphes, permettant d'extraire automatiquement des éléments de fissure. Nous comparons cette méthode à une méthode par *transfer*

*learning*, permettant de montrer que la technique offre des résultats équivalents, voire légèrement supérieurs, tout en faisant intervenir un nombre très limité de paramètres et sans nécessiter de données annotées. Notre objectif n'est pas seulement de segmenter l'image, c'est-à-dire déterminer pour chaque pixel s'il appartient ou non à une fissure ; nous souhaitons extraire complètement le réseau de fissures contenu au sein d'une image. Pour ce faire, nous reprenons les idées du filtre de FRANGI, aussi qualifié de *multiscale Hessian-based filtering*, en les généralisant.

Le filtre de FRANGI [3, 9] est un algorithme classique en traitement d'image pour faire ressortir les structures tubulaires. Originellement utilisé pour des images médicales (détection de vaisseaux sanguins par exemple), il est tout aussi adapté au cas des images obtenues en géosciences [17]. L'algorithme de FRANGI ne dépend que d'un petit nombre de paramètres, dont l'apprentissage peut se faire rapidement (voir à ce sujet [4]). Autre avantage : le filtre de FRANGI s'applique tout aussi bien à des images 2D que 3D. À la différence du *filtre* de FRANGI, qui fournit une réponse en chaque pixel de l'image, nous construisons un *graphe* de FRANGI pour chaque paire de pixels voisins. Cette généralisation permet de recueillir des informations plus précises : en observant les données en deux points, on peut mieux en inférer si ces deux points appartiennent à la *même* structure tubulaire. Comme cette méthode fournit un graphe en sortie du premier algorithme (ALG. 1),

l'on dispose ensuite de nombreux algorithmes à lui appliquer (pour la classification, d'élagage, de post-traitement, *etc.*).

Dans cette contribution, nous comparons nos résultats avec ceux d'une méthode récente d'apprentissage profond couplée à du *transfer learning* [13]. Les images employées (les deux en FIG. 1 ainsi que celle, plus grande, utilisée pour l'apprentissage) ont été prises par drone, comme décrit dans [2]. La vérité terrain pour les trois images a été fournie par un expert en géosciences. Nous donnons les résultats en image des deux algorithmes. Trois mesures classiques sont utilisées pour les résultats chiffrés : l'indice de JACCARD [7] / TVERSKY [14] et la distance de WASSERSTEIN [16].

Dans la suite de l'article, nous décrivons la méthode proposée (§ 2), puis discutons des résultats obtenus (§ 3) et concluons avec quelques perspectives (§ 4).

## 2 Méthode proposée : FRANGI pour l'extraction des fissures

### 2.1 Graphe de FRANGI-généralisé

Une image  $I$  peut être vue comme un signal  $I : \mathcal{X} \subset \mathbb{R}^d \rightarrow \mathbb{R}$  de la grille sur  $\mathbb{R}^d$  (avec  $d = 2$  ou  $d = 3$ ) vers  $\mathbb{R}$ . L'algorithme de FRANGI repose sur l'analyse des matrices hessiennes du signal  $I$ . L'idée est simple : tout comme le gradient en  $\vec{x} \in \mathcal{X}$  fournit le plan qui approche localement au mieux le signal, la hessienne donne le meilleur paraboloïde d'approximation (développement limité à l'ordre 2 de  $I(\vec{x} + \vec{h})$ ).

En observant la forme de ce paraboloïde, on peut en déduire l'appartenance ou non d'un pixel à une structure tubulaire. En regardant le sens du paraboloïde, on en déduit si cette structure est un "trou" ou bien une "bosse". Ces observations doivent se faire sur un ensemble d'échelles  $\sigma \in \Sigma$  soigneusement défini, en fonction de la résolution de l'image et de la taille souhaitée des structures à détecter.

Soit  $\vec{x} \in \mathcal{X}$  un pixel d'une image sur  $\mathbb{R}^2$ , la hessienne  $H_\sigma(\vec{x})$  prise à l'échelle  $\sigma$  est une matrice réelle symétrique  $2 \times 2$  que l'on peut donc décrire par ses deux valeurs propres  $\lambda_1, \lambda_2$  (avec  $|\lambda_2| \geq |\lambda_1|$ ) ainsi qu'une rotation d'angle  $\theta$  par rapport à la base canonique. Pour mesurer le degré d'appartenance d'un pixel  $\vec{x} \in \mathcal{X}$  à une structure tubulaire, le filtre de FRANGI renvoie le produit de réponses sur l'intensité du signal et l'élongation du paraboloïde décrit par  $H_\sigma(\vec{x})$ . Ces réponses sont calculées via une fonction gaussienne dépendant d'un paramètre qui joue le rôle de l'écart-type,  $\beta \leftarrow \frac{1}{2}$  pour la réponse sur l'élongation de la structure tubulaire et d'un paramètre  $c \leftarrow \frac{1}{4}$  pour la réponse sur l'intensité locale du signal.

La généralisation de ces mesures de *similarité* à une structure tubulaire pour des paires de pixels  $\vec{x}, \vec{x}' \in \mathcal{X}$  se fait assez naturellement; dans l'ALG. 1, elles correspondent aux variables `SimElong` (pour la mesure d'élongation) et `SimInt` (pour la mesure d'intensité). L'intérêt de regarder des paires de points par rapport à l'algorithme classique de FRANGI est que l'on peut aussi mesurer l'alignement (variable `SimAng`) des structures tubulaires en utilisant les angles  $\theta$  et  $\theta'$  associés à chaque point. Un dernier paramètre  $c_\theta \leftarrow \frac{1}{8}$  est introduit pour l'écart-type maximum souhaité au niveau de l'alignement. L'ALG. 1 décrit la construction du graphe de similarité, que nous appellerons graphe de FRANGI-généralisé.

---

### Algorithme 1 : Graphe de FRANGI-généralisé

---

**Entrées :** Une image  $I : \mathcal{X} \subset \mathbb{R}^2 \rightarrow \mathbb{R}$ , le rayon  $R$  de voisinage,  $\beta \leftarrow \frac{1}{2}$ ,  $c \leftarrow \frac{1}{4}$ ,  $c_\theta \leftarrow \frac{1}{8}$ ,  
 $\Sigma \leftarrow \{1; 3; 5; 7; 9\}$

**Sorties :** Graphe de FRANGI-généralisé  $G$

**pour**  $\vec{x}, \vec{x}' \in \mathcal{X}$ ,  $\|\vec{x} - \vec{x}'\| \leq R$  **faire**

**pour**  $\sigma \in \Sigma$  **faire**

$N \leftarrow \|H_\sigma\|$

$(\lambda_1, \lambda_2, \theta), (\lambda'_1, \lambda'_2, \theta') \leftarrow H_\sigma(\vec{x}), H_\sigma(\vec{x}')$

**si**  $\min(\lambda_2, \lambda'_2) > 0$  **alors**

$\text{SimElong} \leftarrow e^{-\frac{1}{2} \frac{1}{\beta^2} \left( \left| \frac{\lambda_1}{\lambda_2} \right| + \left| \frac{\lambda'_1}{\lambda'_2} \right| \right)^2}$

$\text{SimInt} \leftarrow 1 - e^{-\frac{1}{2} \frac{1}{c^2} \frac{|\lambda_2 \lambda'_2|}{N^2}}$

$\text{SimAng} \leftarrow e^{-\frac{1}{2} \frac{1}{c_\theta^2} \sin(\theta - \theta')^2}$

$G_\sigma(\vec{x}, \vec{x}') \leftarrow \text{SimElong} \cdot \text{SimInt} \cdot \text{SimAng}$

**fin**

**fin**

$G(\vec{x}, \vec{x}') \leftarrow \max_{\sigma \in \Sigma} G_\sigma(\vec{x}, \vec{x}')$

**fin**

---

### 2.2 Un premier arbre de classification hiérarchique

Une fois le graphe de similarité obtenu (puis transformé en graphe de distance), l'on peut appliquer nombre d'algorithmes de clustering hiérarchiques de la même famille que HDBSCAN [11]. En l'occurrence, nous recourons à des structures un peu plus robustes que les simples composantes connexes du graphe : les composantes "triangles-connexes" (voir [6]).

### 2.3 Élagage de l'arbre et choix de la filtration finale

Après obtention de l'arbre de *clustering* hiérarchique, on lui applique un algorithme pour l'élaguer et n'en conserver que les nœuds les plus importants (voir à ce sujet un Notebook Python [5]). Il n'y a plus qu'à choisir un niveau dans l'arbre hiérarchique (une *filtration*  $\tau$ , fixée à 0,3 de façon *ad-hoc*). Noter que ce réseau est, par construction, une forêt et qu'un post-traitement pourrait être nécessaire pour certaines images où le réseau de fissures formerait des cycles.

## 3 Expérimentations

### 3.1 Descriptions des images tests

Les tests ont été réalisés sur deux images  $512 \times 512$  prises par drone au niveau du glissement des Vaches Noires à Villers-sur-Mer (Calvados) et qui possède une morphologie de badland, cf. [2]. Les images montrées sur la FIG. 1 constituent deux zones de fissuration différentes, de plus prises à des saisons différentes (hiver 2019 par temps clair, figure de gauche et printemps 2018 par temps couvert, figure de droite). Les images ont été acquises à 110 m de hauteur grâce à un drone DJI Phantom 4 en mai 2018 (résolution de 3 cm) et un drone DJI M600 équipé d'une caméra X3 en janvier 2019 (résolution au sol de 3,61 cm).



le graphe de similarité ainsi construit contient davantage d'information. En lui appliquant des algorithmes de classification hiérarchique (avec élagage), nous obtenons un réseau de fissures. Cette méthode nouvelle donne déjà des résultats tout à fait encourageants, et comparables à ceux d'une méthode d'apprentissage profond couplée à du *transfer learning*. On notera que cette dernière n'est pas aussi "universelle" qu'annoncée : l'entraînement, même réduit, reste indispensable pour une bonne extraction de fissures, et il doit se faire sur des images similaires à celles testées. Or, l'annotation d'une vérité terrain est un travail long et fastidieux, qui ne peut être bien fait que par un expert.

Notre méthode a le grand avantage de se passer complètement de vérité terrain et ne requiert qu'un petit nombre de paramètres qui peuvent être estimés de façon *ad hoc*. Les différents tests que nous avons faits ont montré que ces paramètres pouvaient être légèrement changés sans incidence particulière sur les résultats. Ces bonnes propriétés restent à confirmer sur un plus large jeu de données. À la lumière de ces résultats, nous prévoyons d'étendre l'étude en 3D en appliquant très bientôt notre méthode à des nuages de points obtenus par photogrammétrie. Ce nouveau type de données nous permettra d'ajouter des *a priori* géométriques lors de la construction du graphe de FRANGI-généralisé pour mieux distinguer les véritables fissures des rigoles d'écoulement d'eau.

**Notes des auteurs.** Le code informatique permettant la construction d'un arbre hiérarchique à partir d'un graphe (cf. §2.2) faisant l'objet d'une collaboration industrielle potentielle ne peut être rendu public à ce jour.

**Remerciements** Les auteurs de l'Inria remercient Bpifrance pour son soutien financier partiel *via* le contrat LiChIE (2020-2025). Le premier auteur remercie également l'Université Côte d'Azur (UniCA) *via* ses programmes DS4H (ANR-17-EURE-0004) et 3IA (ANR-19-P3IA-0002) pour le financement de sa thèse.

Le second auteur remercie la Région Normandie et le Fonds Européen de Développement Régional (FEDER) pour le financement du projet DEFHY3GEO (Détection et Étude de la Fracturation par approche HYdrologique, GEOMorphodynamique, GEOlogique et GEOphysique, 2022-2024).

## Références

- [1] E. BIRD : *Coastal cliffs : morphology and management*. Springer, 2016.
- [2] C. FAUCHARD, V. GUILBERT, R. ANTOINE, C. LEDUN, B. BEAUCAMP, O. MAQUAIRE, S. COSTA, M. MEDJ-KANE et T. ROULLAND : Diachronic UAV study of coastal badlands supported by geophysical imaging in the context of accelerated erosion processes. *Landslides*, 20(5):1065–1082, 2023.
- [3] A. F. FRANGI, W. J. NIESSEN, K. L. VINCKEN et M. A. VIERGEVER : Multiscale vessel enhancement filtering. *In Medical Image Computing and Computer-Assisted Intervention*. Springer, 1998.
- [4] T. HACHAJ et M. PIEKARCZYK : High-Level Hessian-Based Image Processing with the Frangi Neuron. *Electronics*, 12(19), 2023.
- [5] L. HAUSEUX : *K*-centroïdes dans un arbre, 2024. Google Colaboratory Python Notebook.
- [6] L. HAUSEUX, K. AVRACHENKOV et J. ZERUBIA : Hypergraphs, percolation, and hierarchical clustering. *In* SPRINGER, éd. : *The 13th International Conference on Complex Networks and their Applications*, Studies in Computational Intelligence, Istanbul, Turkey, déc. 2024.
- [7] P. JACCARD : Distribution de la flore alpine dans le bassin des Dranses et dans quelques régions voisines. *Bulletin De La Société Vaudoise Des Sciences Naturelles*, 1901.
- [8] B. JAFRASTEH, I. MANIGHETTI et J. ZERUBIA : Generative adversarial networks as a novel approach for tectonic fault and fracture extraction in high resolution satellite and airborne optical images. *In XXIV International Society of Photogrammetry and Remote Sensing Congress*, vol. XLIII-B3-2020, p. 1219–1227, Nice, France, août 2020.
- [9] Z. LAMBERT : *Contraintes géométriques et topologiques pour la segmentation d'images médicales : approches hybrides variationnelles et par apprentissage profond*. Thèse de doctorat, 2022.
- [10] L. MATTÉO, I. MANIGHETTI, Y. TARABALKA, J.-m. GAUCEL, M. van den ENDE, A. MERCIER, O. TASAR, N. GIRARD, F. LECLERC, T. GIAMPETRO, S. DOMINGUEZ et J. MALAVIEILLE : Automatic fault mapping in remote optical images and topographic data with deep learning. *Journal of Geophysical Research : Solid Earth*, avr. 2021.
- [11] L. MCINNES et J. HEALY : Accelerated hierarchical density based clustering. *In IEEE International Conference on Data Mining Workshops (ICDMW)*, p. 33–42, 2017.
- [12] Y. SHI : Crack Detection and Transfer Learning, 2022. Google Colaboratory Python Notebook.
- [13] Y. SHI, M. BALLELIO, K. JOHANSEN, D. TRENTMAN, Y. HUANG, M. F. MCCABE, R. BRUHN et G. SCHUSTER : Semi-universal geo-crack detection by machine learning. *Frontiers in Earth Science*, 11:1073211, 2023.
- [14] A. TVERSKY : Features of similarity. *Psychological Review*, 84(4):327–352, 1977.
- [15] S. Van der WALT, J. L. SCHÖNBERGER, J. NUNEZ-IGLESIAS, F. BOULOGNE, J. D. WARNER, N. YAGER, E. GOUILLART et T. YU : scikit-image : image processing in python. *PeerJ*, 2:e453, 2014.
- [16] L. N. VASERSTEIN : Markov processes over denumerable products of spaces, describing large systems of automata. *Problemy Peredači Informacii*, 5(3):64–72, 1969.
- [17] T. ZHAO, Y. YUE, T. CHEN et F. QIAN : 3D Seismic Attribute Conditioning Using Multiscale Sheet-Enhancing Filtering. *Remote Sensing*, 17(2), 2025.