

Réseaux de neurones morphologiques



Mots-clés: morphologie mathématique, couches morphologiques, réseaux de neurones, IA explicable

Contexte

La morphologie mathématique est un sous-domaine du traitement d'images qui met en œuvre des techniques de filtrage non-linéaire se basant sur des formes géométriques (carré, croix, disque, ligne, etc), appelés *élément structurant* et permettant de sonder le contenu de l'image [1]. Les opérations de base de la morphologie mathématique sont l'érosion et la dilatation, et leur composition permet de définir des opérations plus poussées telles que l'ouverture et la fermeture, le gradient morphologique, etc. Ces opérations de morphologie mathématique sont usuellement utilisées dans un contexte où l'élément structurant est binaire, et l'image est soit binaire, soit en niveaux de gris. Cependant, ces opérations peuvent également être définies avec des *fonctions structurantes* (i.e., des éléments structurants en niveaux de gris).



Exemple d'une opération d'érosion \ominus et de dilatation \oplus d'une image MNIST par un élément structurant circulaire.

La morphologie mathématique est très performante pour diverses applications en traitement d'images telles que le débruitage ou la détection d'objets. Cependant, ces performances dépendent bien souvent de l'expertise et de la capacité de l'utilisateur à déterminer le bon enchaînement des opérations de base et la bonne définition de leur élément structurant associé pour la tâche à accomplir. La définition automatique des opérations de morphologie mathématique et leur élément structurant pour une application donnée est donc une perspective particulièrement attrayante.

Plusieurs travaux ont récemment été proposés pour intégrer l'apprentissage automatique de séquence d'opérations morphologiques dans le cadre des réseaux de neurones convolutionnels [2–10]. Plus particulièrement, l'objectif est de remplacer les couches convolutionnelles classiques par des couches morphologiques permettant d'appliquer des érosions ou des dilations. Les poids du filtre s'apparentent ainsi à la fonction structurante associée. Cependant, les opérations d'érosion et de dilatation étant (localement) non-différentiables puisque leur définition se base sur des minimas ou maximas ensemblistes, des stratégies détournées doivent être mises en place pour garantir la bonne convergence du réseau durant la phase d'apprentissage. Les deux stratégies ayant émergées dans la littérature sont l'utilisation d'approximations lisses et différentiables des opérateurs de minimum et maximum [2–4,9,10] ou la prise en charge de la couche morphologique de la même manière que sont gérées les opérations localement non-différentiables des architectures classiques (telles que le *max-pooling*) [5–8].

Récemment, nous avons proposé dans [9], et étendu dans [10], deux nouvelles couches morphologiques basées sur des approximations lisses et différentiables des opérateurs de minimum et maximum. Nous avons montrés que ces couches étaient capable d'apprendre de manière très performantes les opérations d'érosion, dilatation, ouverture et fermeture ainsi que l'élément structurant associé. Cependant, certaines propriétés de ces couches restent mal comprises, voir incomprises, en particuliers sur les cas où l'apprentissage est un échec, et les différentes évaluations ont été conduites jusqu'à présent sur des jeux de données relativement basiques.

Objectif

L'objectif du stage est d'explorer plus en profondeur le comportement de ces couches morphologiques, aussi bien sur des aspects théoriques (comportement asymptotique, convergence durant la phase d'apprentissage) que pratiques (capacité à apprendre des opérations morphologiques plus complexes que érosion/dilatation et ouverture/fermeture). Plus particulièrement, les pistes suivantes pourront être explorées :

- Partage des poids entre deux couches morphologiques successives pour l'apprentissage exact de l'ouverture et la fermeture.
- Apprentissage de l'opération *top-hat* et de la transformation en tout ou rien.
- Évaluation d'architectures de réseaux morphologiques plus complexes pour des applications de débruitage ou de détection de contours.

Candidat

Le candidat ou la candidate doit être d'un niveau M2 ou équivalent (dernière année d'école d'ingénieur) en spécialisation informatique / mathématiques appliquées / traitement du signal et des images / intelligence artificielle. Compétences requises pour le stage :

- Principes fondamentaux de l'apprentissage automatique
- Connaissance des bases de la morphologie mathématique
- Programmation en Python (numpy, scipy, matplotlib...)
- Expérience dans les méthodes de deep learning et les bibliothèques associées en Python (Keras, Tensorflow, Pytorch)
- Capacité à conduire et analyser des tests/benchmarks de manière rigoureuse et ordonnée.

Le stage sera basé au **LRE** (Laboratoire de Recherche de l'EPITA, anciennement **LRDE**), au Kremlin-Bicêtre, près de Paris.

Contact et candidature

Les encadrants du stage sont :

- Guillaume Tochon, Enseignant-Chercheur, LRE, EPITA Paris, France.
- Jesus Angulo, Directeur de Recherche, Centre de Morphologie Mathématique, MINES Paris, France.

Est également impliquée sur le projet :

- Élodie Puybareau, Enseignante-Chercheuse, LRE, EPITA Paris, France.

Rémunération 1000€ brut/mois

Début du stage Entre mi-février et mi-avril

Durée du stage 5/6 mois

Merci d'envoyer votre candidature (CV, lettre de motivation, relevé de notes du M1/2^e année de cycle ingénieur + descriptif du M2/3^e année de cycle ingénieur) à guillaume.tochon@lrde.epita.fr

Références

- [1] J. Serra, "Introduction to mathematical morphology," *Computer vision, graphics, and image processing*, vol. 35, no. 3, pp. 283–305, 1986.
- [2] J. Masci, J. Angulo, and J. Schmidhuber, "A learning framework for morphological operators using counter-harmonic mean," in *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing*, pp. 329–340, Springer, 2013.
- [3] D. Mellouli, T. M. Hamdani, J. J. Sanchez-Medina, M. B. Ayed, and A. M. Alimi, "Morphological convolutional neural network architecture for digit recognition," *IEEE transactions on neural networks and learning systems*, vol. 30, no. 9, pp. 2876–2885, 2019.

- [4] F. Y. Shih, Y. Shen, and X. Zhong, “Development of deep learning framework for mathematical morphology,” *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 33, no. 06, p. 1954024, 2019.
- [5] G. Franchi, A. Fehri, and A. Yao, “Deep morphological networks,” *Pattern Recognition*, vol. 102, p. 107246, 2020.
- [6] R. Mondal, M. S. Dey, and B. Chanda, “Image restoration by learning morphological opening-closing network,” *Mathematical Morphology-Theory and Applications*, vol. 4, no. 1, pp. 87–107, 2020.
- [7] K. Nogueira, J. Chanussot, M. Dalla Mura, and J. A. Dos Santos, “An introduction to deep morphological networks,” *IEEE Access*, vol. 9, pp. 114308–114324, 2021.
- [8] S. K. Roy, R. Mondal, M. E. Paoletti, J. M. Haut, and A. Plaza, “Morphological convolutional neural networks for hyperspectral image classification,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 8689–8702, 2021.
- [9] A. Kirszenberg, G. Tochon, É. Puybareau, and J. Angulo, “Going beyond p-convolutions to learn grayscale morphological operators,” in *International Conference on Discrete Geometry and Mathematical Morphology*, pp. 470–482, Springer, 2021.
- [10] R. Hermary, G. Tochon, É. Puybareau, A. Kirszenberg, and J. Angulo, “Learning grayscale mathematical morphology with smooth morphological layers,” *Journal of Mathematical Imaging and Vision*, pp. 1–18, 2022. <https://www.lrde.epita.fr/dload/papers/hermary.22.jmiv.pdf>.