

Introduction A La Recherche En Laboratoire
Analyse par apprentissage supervisé d'images CT
de fractures du bassin

Maxime Nemo
Matthieu Chabanas

August 31, 2022

1 Abstract

La segmentation automatique des fractures de l'*acetabulum* est essentielle à la simulation de réduction chirurgicale. Ce rapport propose une première méthode afin de réaliser cette tâche, divisée en deux parties. La première consistant en un réseau de neurones convolutif permettant d'effectuer la segmentation des parties osseuses, et la seconde permettant de séparer les fragments osseux. Nous proposons également dans ce rapport des optimisations et d'autres solutions à explorer pour améliorer la méthode proposée, mais aussi un moyen de traitement des données disponibles pour générer un nouveau jeu de données exploitable pour un entraînement de réseau de neurones

2 Introduction

Les fractures de l'*acetabulum*, cavité du bassin accueillant la tête du fémur, nécessitent en général un scanner (image CT), afin de localiser et classifier les fractures selon leur type d'après la classification de Letournel [1]. Il est alors possible de segmenter les fragments osseux afin de les visualiser en 3D, mais surtout d'effectuer une simulation de réduction chirurgicale [2] (figure 1) afin de valider ou non le planning chirurgical proposé. Actuellement, une telle segmentation est semi-automatique et prend entre 2h et 3h ce qui est trop long pour une utilisation routinière de l'outil de simulation. L'objectif est alors d'exploiter les nouvelles méthodes, et notamment les nouveautés en *deep-learning* pour automatiser ce processus de segmentation pour lequel une bonne précision est requise étant donné son application médicale.

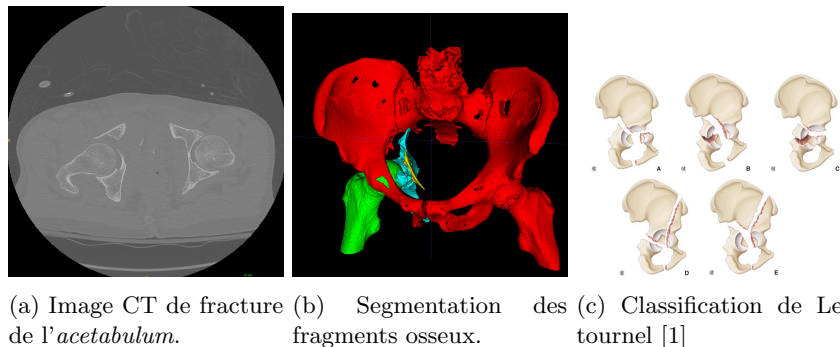


Figure 1

La segmentation d'os pose de nombreux problèmes: la densité de l'os cortical est très différente de celle de l'os spongieux ce qui fait qu'ils apparaissent très différemment sur les images CT. De plus, la détermination du trait de fracture est aussi chose difficile, même pour une personne expérimentée.

Les modèles existants aujourd'hui pour la segmentation d'os [3–10] sont principalement de deux types. Le premier utilise des méthodes de *Thresholding*,

Region Growing ou encore *Active Shape Modeling* [9, 10]. Ces méthodes se focalisent alors sur les informations locales en niveau de gris dans les images CT. Le second type utilise des réseaux de neurones convolutifs (CNN) [3–8] qui atteignent souvent de meilleurs résultats que les méthodes plus classiques. Le plus souvent, ces CNN sont des réseaux de type U-Net, réseau spécialisé dans la segmentation, avec une partie encodeur et une partie décodeur.

Cependant, peu de travaux se sont intéressés à la segmentation du bassin [7, 9, 10]. Enfin, lorsque l’on cherche cette fois-ci à segmenter des fractures de l’*acetabulum*, le sujet n’a pratiquement pas été étudié [9]. Cependant, les résultats de la méthode proposée par Wu *et al.* ne permettent pas d’utiliser cette méthode à des fins médicales car la segmentation n’est pas assez précise.

Liu *et al.* ont traité des fractures du bassin dans leurs travaux. Bien qu’ils n’aient pas travaillé sur des fractures de l’*acetabulum*, mais sur des fractures de bassin en général, la méthode proposée semble bien adaptée à notre problème, même si elle ne permet pas de répondre entièrement à celui-ci. En effet, Liu *et al.* avaient pour objectif de segmenter dans des classes différentes la colonne lombaire, le sacrum, l’iliaque gauche et l’iliaque droite et, en présence de fragments, les associer à la classe la plus proche. Or, nous souhaitons, au contraire, associer à chaque fragment une instance différente de la classe ”os”. De plus, la segmentation produite ne comprend pas le fémur. Cependant, si le réseau utilisé est capable de reconnaître le fémur et de ne pas le segmenter, il est totalement envisageable qu’il soit capable de le segmenter en l’adaptant.

Finalement, d’autres travaux se sont focalisés sur la localisation de fractures osseuses [9, 11–15], mais encore très peu se sont intéressés aux fractures du bassin [9, 13, 14] avec un AUC (*Area Under the Curve*) allant jusqu’à 0.975 à partir d’images X-Ray pour les travaux de Wang *et al.*

3 Méthode

3.1 Méthodologie générale

L’objectif de cet IRL est de segmenter dans des instances différentes les fragments osseux. Il s’agit en fait d’une segmentation panoptique. Cela signifie que l’on souhaite avoir une segmentation sémantique, ici, savoir s’il s’agit d’une partie osseuse ou non, couplée à une segmentation d’instance (deux fragments osseux sont des éléments séparés) en même temps. Il existe plusieurs façons d’aborder le sujet (figure 2). Nous avons tout d’abord souhaité commencer effectuer une segmentation panoptique en cascade (figure 2 d)). On commence donc par effectuer une segmentation sémantique, puis effectuer la segmentation d’instance dans un second temps.

3.2 Expérimentations

3.2.1 Les données

Les données utilisées nous ont été fournies par le CHU Grenoble Alpes. Nous avons eu accès en début de projet aux images CT et leur segmentation associée pour 7 patients avec des fractures diverses de l'*acetabulum*. Ce nombre de patient aurait pu être suffisant pour effectuer des segmentations 2D, mais trop limitant pour des segmentations 3D en partant d'un modèle non pré-entraîné. Cependant, la segmentation 3D permet d'obtenir de meilleurs résultats puisqu'elle permet de mieux capturer le contexte spatial.

De plus, la segmentation des données fournies n'est pas parfaite (figure 5 et 6, Ground Truth). Il y a des imperfections tels que des petits trous dans les zones de faible intérêt par exemple. Enfin, la partie du bassin qui n'est pas fracturée est parfois non segmentée par gain de temps puisqu'elle n'apporte rien de plus dans la simulation qui sera effectuée avec cette segmentation. Cependant, cela fait qu'un travail sur les données risque d'être requis pour les uniformiser.

3.2.2 Segmentation sémantique

Il apparaissait attrayant d'utiliser le modèle proposé par Liu *et al.* [7] puisqu'il a été entraîné sur plus de 1000 images CT 3D de bassin provenant de jeu de données de différentes sources, ce qui devrait améliorer la robustesse du modèle et puisqu'il est *open source*. Il a alors fallu adapter le code pour qu'il puisse fonctionner sur le serveur GPU du laboratoire et pour qu'il puisse être utilisé à grande échelle facilement, c'est-à-dire avec une simple ligne de commande.

Le modèle utilisé est la version cascade du 3D U-Net nnU-Net initialement proposée par Isensee *et al.* [17] et adaptée pour la segmentation d'images CT du bassin par Liu *et al.*. L'architecture en cascade est détaillée dans la figure 3. Le réseau est composé de deux U-Net 3D dont l'architecture est décrite en figure 4. La première partie du réseau effectue un sous-échantillonnage puis une segmentation de faible résolution par bloc avec un U-Net 3D qui va per-

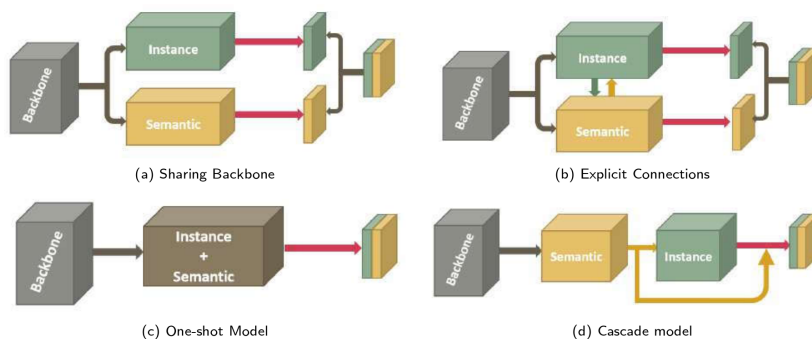


Figure 2: [16] Types de segmentation panoptique.




Figure 3: Modèle cascade adapté par Liu *et al.* [7] suivi du post-traitement SDF.

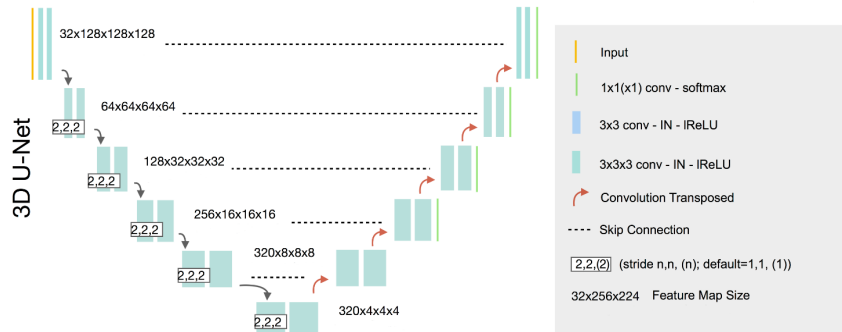


Figure 4: U-Net 3D [17]. Architecture du réseau U-Net 3D. Les réseaux haute et basse résolution ont la même architecture.

mettre de capturer un maximum d'informations contextuelles. Cette première segmentation est ensuite sur-échantillonnée, *one hot* encodée, puis concaténée avec l'image originale pour former l'entrée du second réseau U-Net 3D qui va effectuer une segmentation par bloc de résolution maximale qui va permettre de raffiner la première segmentation. Finalement, un post-traitement nommé SDF introduit par Liu *et al.* est utilisé. Il a pour but de supprimer les impuretés de la segmentation tout en évitant de supprimer les os cassés, qui étaient souvent supprimés par les post traitement habituels. Le modèle que l'on vient de décrire segmente dans des classes différentes la colonne lombaire, le sacrum, l'iliaque gauche et l'iliaque droite (figure 3, *Four class 3D pelvic bones segmentation*). Ces classes ne nous intéressant pas, nous considérons donc qu'il s'agit de partie osseuse sans distinction.

3.2.3 Séparation des instances

L'objectif de cette partie est de séparer les fragments qui sont actuellement dans la même instance en sortie de la segmentation sémantique. Une première approche a été d'utiliser une ouverture morphologique, constituée d'une érosion




Figure 5: Résultat de la segmentation sémantique puis de l’ouverture. Les 3 dernières images sont un zoom sur la zone d’intérêt. Tous les fragments ne sont pas bien séparés après l’ouverture




Figure 6: Résultat de la segmentation sémantique puis de l’ouverture. Les 3 dernières images sont un zoom sur la zone d’intérêt. La fracture incomplète n’a produit qu’un seul fragment conformément au *ground truth*.

suivie d’une dilatation, pour effectuer cette étape du traitement. Convert3D, un outil de traitement d’images médicales, propose de telles manipulations, nous avons donc utilisé cet outil.

Nous commençons par regrouper dans la même classe la colonne lombaire, le sacrum, l’iliaque gauche et l’iliaque droite qui sont séparées en sortie de la segmentation sémantique proposée ci-dessus. Ensuite, on applique une érosion avec un filtre $3 \times 3 \times 3vox$. Cela permet de séparer des instances qui étaient auparavant connectées. On sépare ensuite les fragments osseux qui ne sont pas en contact en les plaçant dans des instances différentes. Finalement, on applique une dilatation de filtre $3 \times 3 \times 3vox$ pour retrouver une forme plus proche de l’originale.

Le module IRL étant de courte durée, nous n’avons pas eu le temps d’essayer d’autres méthodes, notamment par réseau de neurones, pour effectuer la segmentation d’instance de la segmentation panoptique en cascade.

4 Résultats

Les figures 5 et 6 présentent les segmentations obtenues avec la méthode décrite précédemment pour deux patients. On y retrouve, en premier, un extrait de l’image CT, puis la segmentation *ground truth*, et enfin les segmentations produites, avec en premier la segmentation d’instance, puis la segmentation panoptique complète. Finalement, les trois dernières images sont un zoom sur une zone d’intérêt.

La fracture en figure 5 est importante et très marquée. Les fragments osseux sont fortement déplacés par rapport à leur place d’origine sans fracture. La figure 6, quant à elle, montre une fracture incomplète, c’est-à-dire que les

fragments osseux sont encore solidaires.

5 Discussion

Les figures 5 et 6 montrent des segmentations sémantiques très prometteuses. On remarque que les résultats sont proches du *ground truth* pour la sortie après SDF. La majorité des fragments osseux est assez bien segmentée et les parties non fracturées sont très bien segmentées. Les segmentations obtenues ont moins d'impuretés telles que des trous dans la segmentation qui sont présents dans le *ground truth* alors qu'elles ne devraient pas y être présentes. Le modèle utilisé pour la segmentation sémantique est ainsi finalement assez robuste puisqu'il segmente bien nos données sans le moindre re-entraînement, alors que les données que vous avons diffèrent de celles utilisées lors de l'entraînement du modèle. En effet, les images CT que nous avons ont des fractures de l'*acetabulum* et montrent des fragments osseux fortement déplacés, contrairement aux images utilisées par Liu *et al.*, dont certaines ont des fractures du bassin.

On peut tout de même remarquer que certaines parties ne sont pas parfaitement segmentées comme sur la figure 5, *zoom*, où l'on remarque que le fragment osseux en bleu sur le *ground truth* n'a pas été segmenté par le modèle proposé, ce qui peut rendre la seconde partie, c'est-à-dire la séparation des instances, plus compliquée. Ensuite, la figure 5, *zoom*, montre aussi des parties moins bien segmentées après l'ouverture. Les fragments ne sont pas vraiment bien séparés dans des cas assez simples comme celui-ci. Des parties osseuses qui ne devraient pas être dans des instances différentes le sont devenues, et des fragments qui auraient dû être séparés ne l'ont pas été. De plus, la dilatation n'est pas suffisante pour retrouver la forme originale ce qui rend la segmentation bien moins précise qu'elle ne l'était. On peut tout de même noter que cette méthode pour effectuer la segmentation d'instance a correctement segmenté la fracture incomplète (figure 6) en ne séparant pas les deux "fragments" qui sont encore reliés d'un côté.

Nous n'avons pas pu faire de mesures par rapport au *ground truth* puisque les segmentations *ground truth* auxquelles nous avons accès sont incomplètes, car elles n'ont été faites que sur la partie d'intérêt. Or, le modèle proposé segmente tout le bassin et non pas juste le centre d'intérêt. Ainsi, toutes mesures de comparaison sont encore impossibles pour le moment.

6 Travaux futurs

6.1 Les données

Nous sommes pour l'instant fortement limités par les données. Il est maintenant nécessaire d'avoir des segmentations complètes pour effectuer des mesures afin d'évaluer et comparer quantitativement les performances de notre méthode. Un travail sur les données va donc être requis rapidement. Pour cela, on peut envisager utiliser le modèle de segmentation sémantique pour avoir un premier

jet de segmentation, puis ensuite, à l'aide du *ground truth*, ajuster la segmentation manuellement où cela est requis, et également séparer les fragments dans des instances différentes. Finalement, on ajoute à la segmentation de façon semi-automatique, de la même manière que la segmentation est actuellement faite, la tête du fémur qui est nécessaire pour la modélisation qui va utiliser la segmentation que l'on souhaite générer. On se retrouverait alors avec un nouveau jeu de données, entièrement utilisable pour de l'entraînement de réseaux de neurones.

6.2 Amélioration du modèle proposé

Pour effectuer la simulation de réduction chirurgicale, il faut encore segmenter le fémur pour avoir une segmentation complète. Plusieurs méthodes s'offrent alors à nous. On peut potentiellement utiliser un autre réseau de type U-Net spécialisé dans la segmentation du fémur tel que l'ont proposé Shen *et al.* [5] et concaténer les deux segmentations. On pourrait aussi simplement ré-entraîner le réseau actuel avec le nouveau jeu de données créé avec la méthode que l'on vient de proposer.

6.3 Autres méthodes pour la segmentation panoptique

Comme le montre la figure 2, il existe de nombreuses façons d'aborder la segmentation panoptique. on peut alors explorer d'autres méthodes pour proposer une solution plus performante.

- Une idée serait de changer la deuxième étape après la segmentation sémantique, par un second réseau de neurones (figure 2 d)). Celui-ci prendrait en entrée la segmentation sémantique générée par la méthode décrite précédemment (et éventuellement l'image CT pour avoir plus d'informations) et produirait en sortie la segmentation d'instance. On peut pour cela utiliser des réseaux de type EmbedSeg [18] proposé par Lalit *et al.* ou encore des Mask R-CNN [Mask R-CNN]
- Ensuite, on pourrait aussi explorer la solution One-shot model (figure 2 c)). L'idée serait alors de ré-entraîner le réseau qui effectue la segmentation sémantique pour qu'il fasse une segmentation panoptique puisque celui-ci est déjà capable d'extraire des informations essentielles des images CT. On pourrait ainsi garder l'avantage de l'entraînement sur les 1000 patients qui a déjà été fait tout en répondant à notre problème en particulier. Pour ce faire, on propose d'utiliser une *loss function* différente proposée par De Brabandere *et al.* [19]. Cette fonction qui opère au niveau des pixels permet aux CNN de produire une représentation de l'image qui peut ensuite assez simplement être transformée en segmentation d'instance par un post-processing formant les *clusters*. Une telle méthode a un bon potentiel puisque qu'il ne s'agirait pas de faire un entraînement depuis le début mais de partir des poids actuels du réseau.

- Finalement, on peut imaginer une segmentation d'instance divisée en deux sous parties. Une première détectant les fractures à l'aide de réseaux du type Yolo Ukai *et al.* [13]. D'après ce papier, la méthode utilisée a permis de détecter 96,4% des fractures du bassin, ce qui est très prometteur. La seconde sous partie serait alors de séparer la segmentation au niveau de chaque fracture pour former des instances différentes.

7 Conclusion

Nous avons proposé une première solution en deux étapes pour segmenter automatiquement les fragments osseux à partir d'images CT de fractures du bassin. La première partie consistant en une segmentation sémantique est prometteuse et peut être gardée et améliorée tandis que la seconde étape proposée, une érosion-dilatation, ayant pour but de séparer les instances, s'est révélée inadaptée, ne séparant pas assez bien les fragments osseux. Nous avons également proposé d'autres méthodes à explorer pour améliorer les résultats et permettre une segmentation propre et fonctionnelle.

Dans l'éventualité où la segmentation entièrement automatique des fractures s'avère impossible pour le moment, la première étape de segmentation sémantique pourrait être réutilisée par la suite par des chirurgiens comme base de segmentation afin d'accélérer le processus semi-automatique actuellement en place.

8 Remerciements

Je tiens à remercier mon encadrant Matthieu Chabanas pour ses conseils, son aide et pour m'avoir accompagné pendant ce projet. Je remercie également le Dr. Mehdi Boudissa, chirurgien orthopédiste au CHU de Grenoble pour ses retours et pour les données. Enfin, je souhaite remercier le laboratoire TIMC de m'avoir accueilli.

References

1. De Peretti, F. & Bernard de Dompure, R. Traitement chirurgical des fractures du cotyle. fr. *EMC - Techniques chirurgicales - Orthopédie - Traumatologie* **5**, 1–21. ISSN: 02460467. <https://linkinghub.elsevier.com/retrieve/pii/S0246046710517495> (2022) (Jan. 2010).
2. Boudissa, M., Oliveri, H., Chabanas, M. & Tonetti, J. Computer-assisted surgery in acetabular fractures: Virtual reduction of acetabular fracture using the first patient-specific biomechanical model simulator. en. *Orthopaedics & Traumatology: Surgery & Research* **104**, 359–362. ISSN: 18770568. <https://linkinghub.elsevier.com/retrieve/pii/S1877056818300446> (2022) (May 2018).

3. Klein, A., Warszawski, J., Hillengaß, J. & Maier-Hein, K. H. Automatic bone segmentation in whole-body CT images. en. *International Journal of Computer Assisted Radiology and Surgery* **14**, 21–29. ISSN: 1861-6410, 1861-6429. <http://link.springer.com/10.1007/s11548-018-1883-7> (2022) (Jan. 2019).
4. Li, C. *et al.* Automated cortical bone segmentation for multirow-detector CT imaging with validation and application to human studies: Cortical bone segmentation. en. *Medical Physics* **42**, 4553–4565. ISSN: 00942405. <http://doi.wiley.com/10.1118/1.4923753> (2022) (July 2015).
5. Shen, W. *et al.* Automatic segmentation of the femur and tibia bones from X-ray images based on pure dilated residual U-Net. en. *Inverse Problems & Imaging* **15**, 1333. ISSN: 1930-8337, 1930-8345. <https://www.aims sciences.org/article/doi/10.3934/ipi.2020057> (2022) (2021).
6. Noguchi, S., Nishio, M., Yakami, M., Nakagomi, K. & Togashi, K. Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques. en. *Computers in Biology and Medicine* **121**, 103767. ISSN: 00104825. <https://linkinghub.elsevier.com/retrieve/pii/S0010482520301402> (2022) (June 2020).
7. Liu, P. *et al.* Deep learning to segment pelvic bones: large-scale CT datasets and baseline models. en. *International Journal of Computer Assisted Radiology and Surgery* **16**, 749–756. ISSN: 1861-6410, 1861-6429. <https://link.springer.com/10.1007/s11548-021-02363-8> (2022) (May 2021).
8. Jin, L. *et al.* Deep-learning-assisted detection and segmentation of rib fractures from CT scans: Development and validation of FracNet. en. *eBioMedicine* **62**, 103106. ISSN: 23523964. <https://linkinghub.elsevier.com/retrieve/pii/S2352396420304825> (2022) (Dec. 2020).
9. Wu, J. *et al.* Fracture Detection in Traumatic Pelvic CT Images. en. *International Journal of Biomedical Imaging* **2012**, 1–10. ISSN: 1687-4188, 1687-4196. <http://www.hindawi.com/journals/ijbi/2012/327198/> (2022) (2012).
10. Vasilache, S., Ward, K., Cockrell, C., Ha, J. & Najarian, K. Unified wavelet and gaussian filtering for segmentation of CT images; application in segmentation of bone in pelvic CT images. en. *BMC Medical Informatics and Decision Making* **9**, S8. ISSN: 1472-6947. <https://bmcm edinformdecismak.biomedcentral.com/articles/10.1186/1472-6947-9-S1-S8> (2022) (Dec. 2009).
11. Guan, B. *et al.* Automatic detection and localization of thighbone fractures in X-ray based on improved deep learning method. en. *Computer Vision and Image Understanding* **216**, 103345. ISSN: 10773142. <https://linkinghub.elsevier.com/retrieve/pii/S1077314221001764> (2022) (Feb. 2022).

12. Thian, Y. L. *et al.* Convolutional Neural Networks for Automated Fracture Detection and Localization on Wrist Radiographs. en. *Radiology: Artificial Intelligence* **1**, e180001. ISSN: 2638-6100. <http://pubs.rsna.org/doi/10.1148/ryai.2019180001> (2022) (Jan. 2019).
13. Ukai, K. *et al.* Detecting pelvic fracture on 3D-CT using deep convolutional neural networks with multi-orientated slab images. en. *Scientific Reports* **11**, 11716. ISSN: 2045-2322. <http://www.nature.com/articles/s41598-021-91144-z> (2022) (Dec. 2021).
14. Wang, Y. *et al.* Weakly Supervised Universal Fracture Detection in Pelvic X-rays. en. *arXiv:1909.02077 [cs]* **11769**. arXiv: 1909.02077, 459–467. <http://arxiv.org/abs/1909.02077> (2022) (2019).
15. Jiménez-Sánchez, A. *et al.* Weakly-Supervised Localization and Classification of Proximal Femur Fractures. en. *arXiv:1809.10692 [cs]*. arXiv: 1809.10692. <http://arxiv.org/abs/1809.10692> (2022) (Sept. 2018).
16. Elharrouss, O., Al-Maadeed, S., Subramanian, N. & Ottakath, N. Panoptic Segmentation: A Review. en, 29.
17. Isensee, F., Jäger, P. F., Kohl, S. A. A., Petersen, J. & Maier-Hein, K. H. Automated Design of Deep Learning Methods for Biomedical Image Segmentation. en. *Nature Methods* **18**. arXiv: 1904.08128, 203–211. ISSN: 1548-7091, 1548-7105. <http://arxiv.org/abs/1904.08128> (2022) (Feb. 2021).
18. Lalit, M., Tomancak, P. & Jug, F. Embedding-based Instance Segmentation in Microscopy. en. *arXiv:2101.10033 [cs, eess]*. arXiv: 2101.10033. <http://arxiv.org/abs/2101.10033> (2022) (Apr. 2021).
19. De Brabandere, B., Neven, D. & Van Gool, L. Semantic Instance Segmentation with a Discriminative Loss Function. en. *arXiv:1708.02551 [cs]*. arXiv: 1708.02551. <http://arxiv.org/abs/1708.02551> (2022) (Aug. 2017).