

SEGMENTATION D'IMAGES MÉDICALES AVEC ANNOTATIONS LIMITÉES: APPRENTISSAGE AUTO-SUPERVISÉ APPLIQUÉ AUX HÉMORRAGIES INTRA-CÉRÉBRALES

Introduction

L'apprentissage automatique a le potentiel de traiter une quantité importante de données et d'accélérer les progrès en recherche. Une application fréquente en imagerie médicale est la segmentation de lésions ce qui permet notamment le suivi volumétrique sériel de celles-ci. Une application subséquente potentielle est le développement de modèles de prédiction de progression de pathologie. Cependant, les performances de modèles de segmentation automatisée dépendent de la disponibilité de grandes quantités de données de haute qualité. Dans le contexte médical, ceci est souvent prohibitif en raison de la disponibilité limitée d'experts pour une tâche d'annotation chronophage.

Pour remédier à cet obstacle, l'apprentissage auto-supervisé (AAS) permet de tirer avantage des innombrables données non étiquetées afin de pré-entraîner un modèle de segmentation par une tâche prétexte en amont de la tâche de segmentation. Le but de ce projet est d'évaluer le gain potentiel en performances de cette approche appliquée à la segmentation d'hémorragie intra-cérébrale spontanée (HICs). La Figure 1 démontre une schématisation de l'apprentissage auto-supervisé appliqué à la segmentation d'imagerie cérébrale. L'HICs est la cause principale d'accident vasculaire cérébral hémorragique et la source d'une importante morbi-mortalité¹. Un modèle de segmentation automatique permettrait de développer un modèle de prédiction de la progression des HICs. Le but ultime serait d'améliorer la prise en charge et l'issue clinique des patients atteints de HICs.

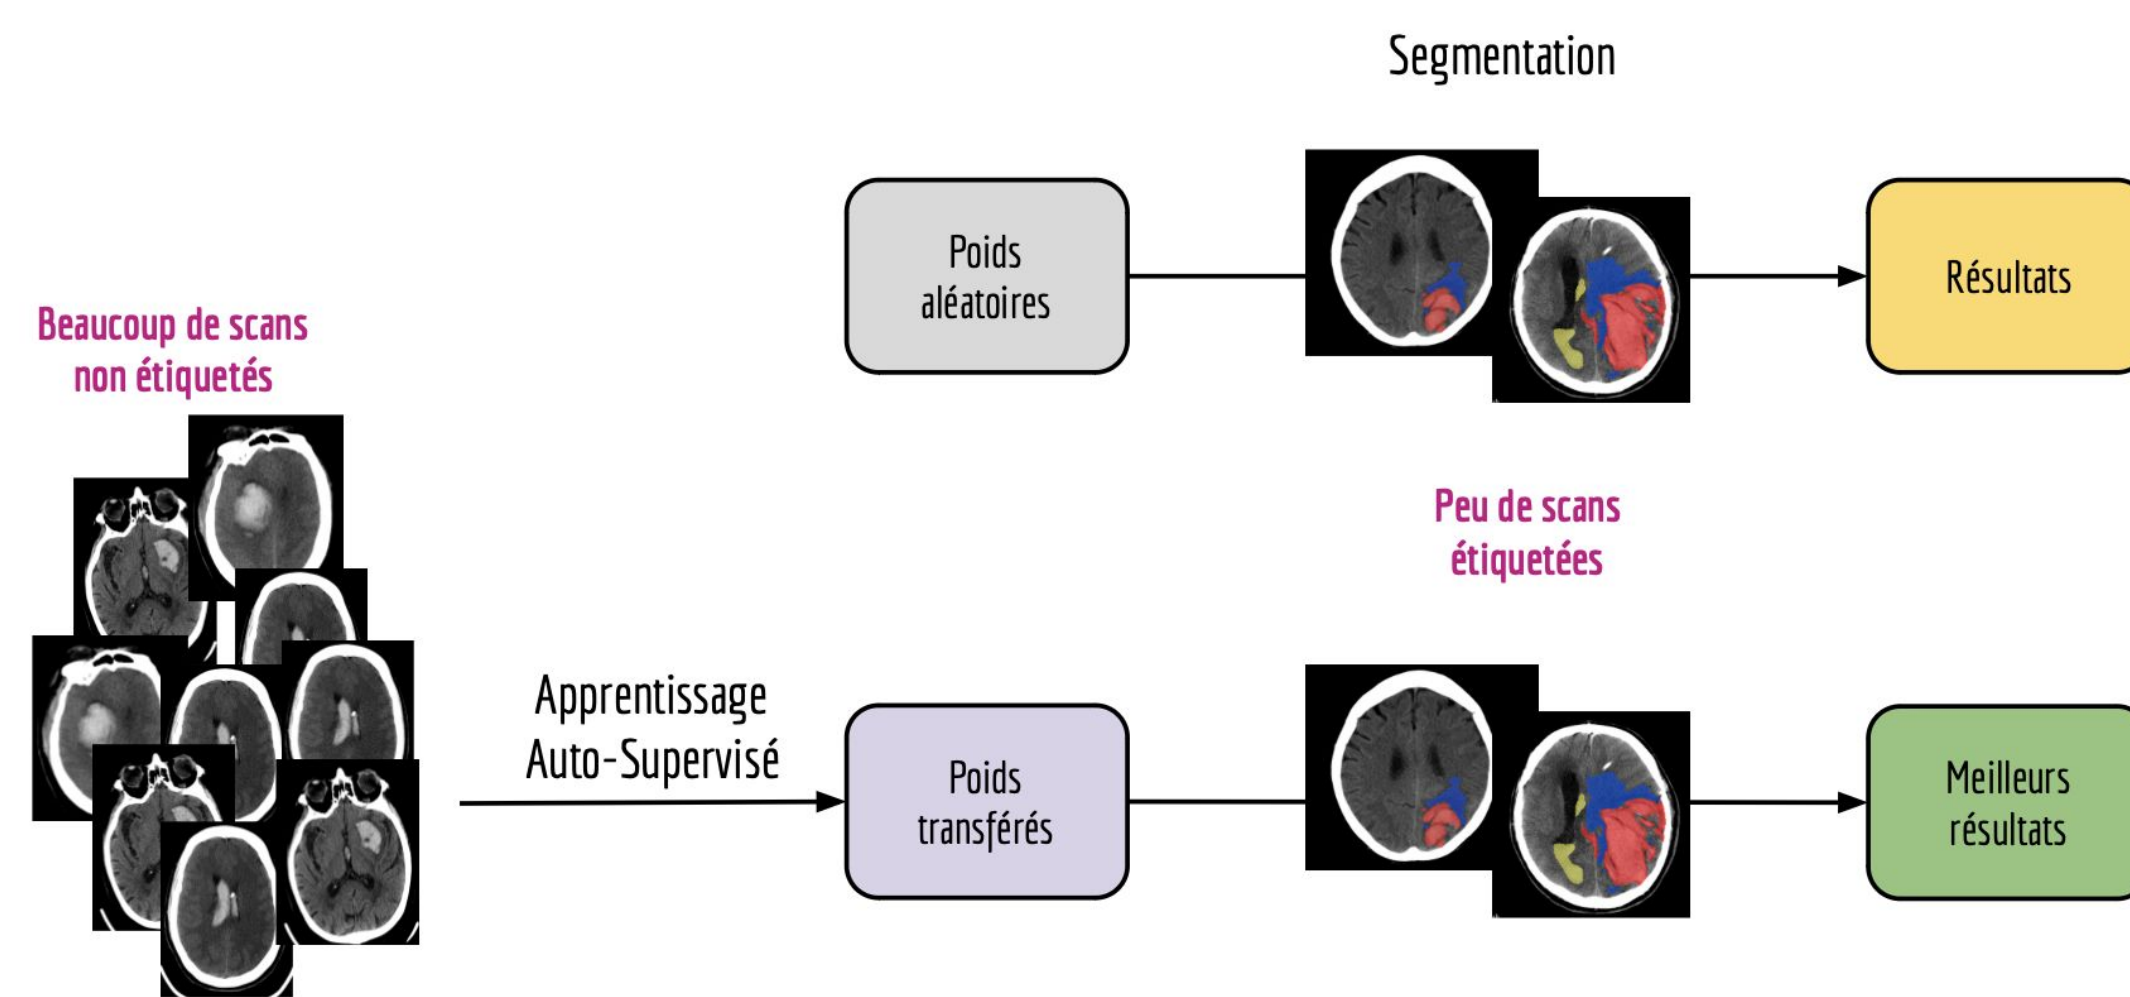


Figure 1: Schématisation de l'apprentissage auto-supervisé appliqué à la segmentation d'imagerie.

Méthodes

(1) Annotation des données

Les CT cérébraux proviennent d'une base de données publique du 2019 *Radiological Society of North America Intracranial Hemorrhage Detection Challenge* ne contenant pas de segmentation². Dre An Ni Wu, Luca Panetta et Delphine Pilon ont effectué une annotation initiale des scans pour la tâche de segmentation, en amont d'une révision éventuelle de la part de Dr Laurent Létourneau-Guillon, neuroradiologue. La Figure 2 démontre une tranche d'un cas annoté comme exemple. Les annotations ont été effectuées à travers l'application *3D Slicer* à l'aide d'une extension développée par Dr Létourneau-Guillon et son équipe. Au courant de l'été, plusieurs améliorations ont été faites à l'extension dont l'ajout d'un outil d'annotation semi-automatique de l'oedème péri-hématome basé sur la méthode décrite par Volbers et al.³ afin de réduire les variations inter-annotateurs.




Figure 2: Exemple d'annotation d'un cas de la base de données du RSNA où l'hémorragie intracérébrale est en rouge, l'hémorragie intraventriculaire est en jaune et l'oedème péri-hématome est en bleu.

Pour la tâche de prétexte, les examens n'ont pas été filtrés selon la présence d'HICs. Pour la tâche de segmentation des HICs en aval, des CT scans non contenus dans le premier échantillon ont été filtrés pour conserver seulement les examens avec HICs. Pour la tâche de prétexte, les examens n'ont pas été filtrés selon la présence d'HICs. Pour la tâche de segmentation des HICs en aval, des CT scans non contenus dans le premier échantillon ont été filtrés pour conserver seulement les examens avec HICs.

(2) Préparation des données

Quelques étapes de préparation de données sont nécessaires avant d'exécuter l'apprentissage par machine. Ces étapes doivent être appliquées aux scans non

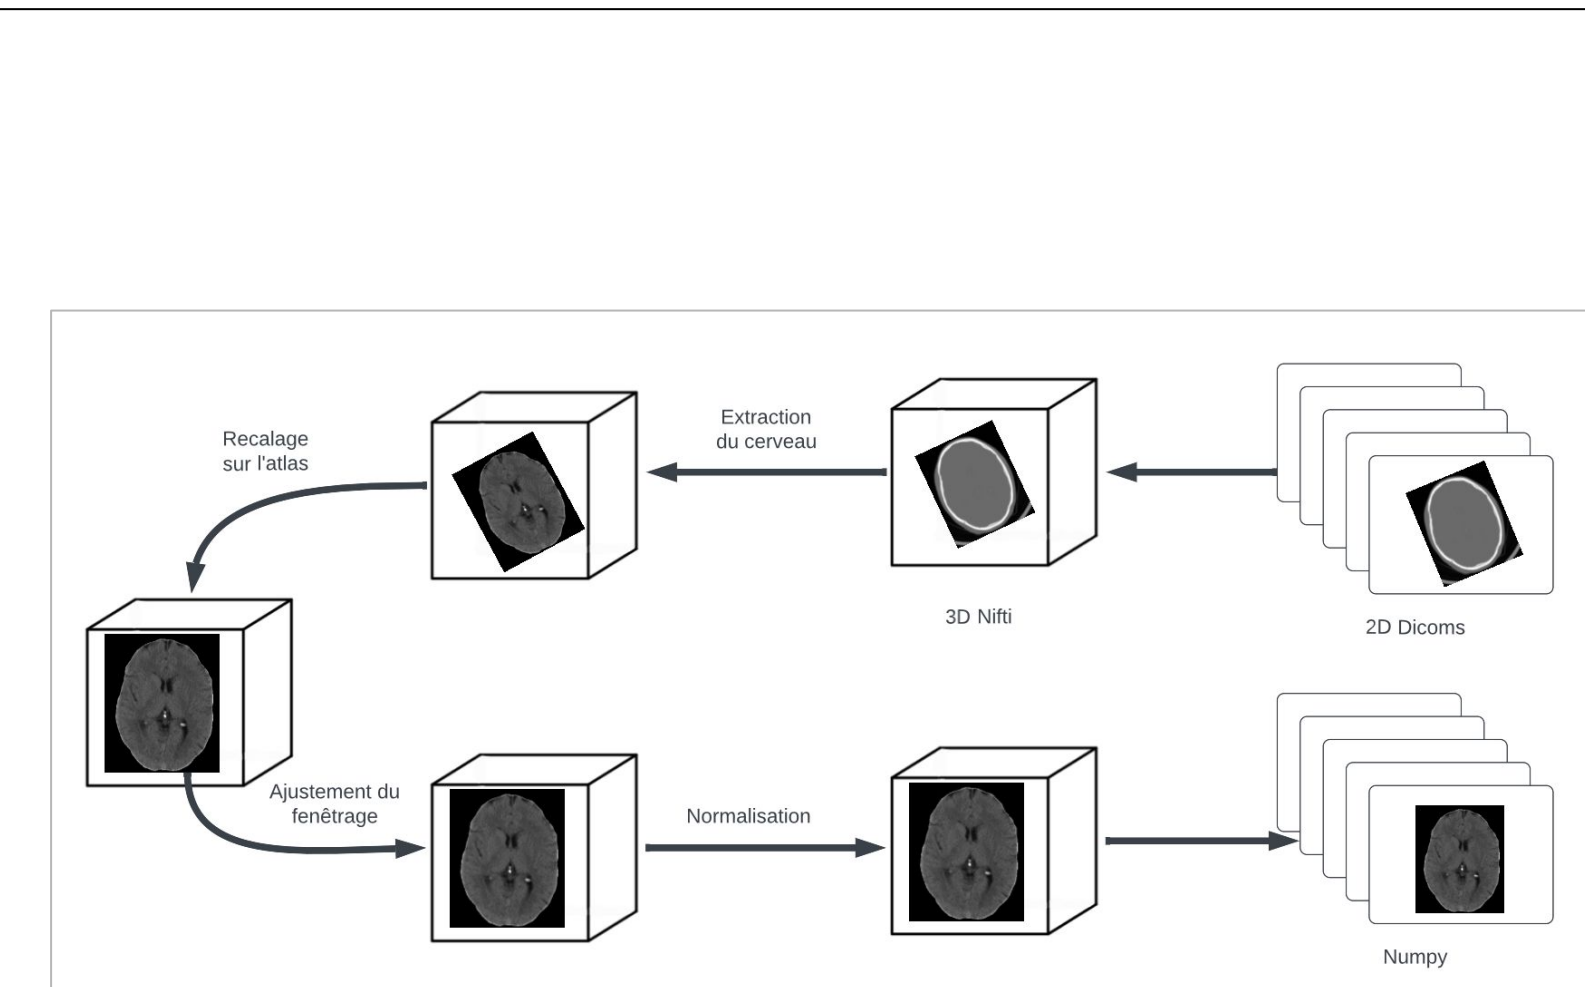


Figure 3: Étapes de préparation des scans cérébraux.

segmentés et aux scans segmentés. En premier lieu, on convertit les fichiers Dicom 2D en Nifti 3D. Ensuite, une extraction du cerveau est effectuée à l'aide de l'outil *CT_BET*⁴ afin de retirer le crâne et les tissus extra crâniens qui sont des structures inutiles à la segmentation d'hémorragies intracérébrales. De plus, on effectue un recalage des volumes sur l'atlas de Muschelli⁵ que l'on a ré-échantillonné à un cube de 128 voxels de large. On effectue un ajustement du fenêtrage (largeur = 80, niveau = 40) puis une normalisation des valeurs entre 0 et 1. La Figure 3 illustre les étapes de préparation des données.

(3) Entraînement et évaluation du modèle

L'apprentissage auto-supervisé exploite les informations inhérentes aux données non étiquetées pour apprendre des représentations utiles à diverses tâches d'apprentissage automatique telle que la segmentation. Durant ce projet, le code de Taleb et al.⁶, *HealthML/self-supervised-3d-tasks*, a été utilisé. Dans leur article, cinq tâches prétextes ont été implémentées en 2D et en 3D, soit *Contrastive Predictive Coding (CPC)*, *Relative Patch Localization*, *Jigsaw*, *Rotation* et *Exemplar*. La tâche prétexte qui offrait le plus d'amélioration de performance sur leur tâche de segmentation du pancréas est *3D CPC*, ce qui explique la sélection de cette tâche dans le cadre du projet actuel. Cette approche tente de prédire les portions manquantes d'une image parcellée en morceaux afin d'apprendre ses caractéristiques importantes. Cette tâche oblige le modèle à apprendre des informations à partir des scans non-étiquetés. Les performances de segmentation ont été évaluées par le coefficient de Dice pondéré pour la taille de la segmentation. Le coefficient de Dice est une métrique de chevauchement spatial d'une paire de segmentation.

Auparavant, Dre Eleyine Zarour a appliqué la tâche prétexte de *2D Contrastive Predictive Coding (CPC)*⁶ en amont d'une tâche segmentation binaire d'HICs. Durant ce projet, on applique la tâche de *3D CPC*⁶ en amont d'une tâche de segmentation multi classe d'HICs, d'hémorragie intraventriculaire (HIV) et d'oedème péri-hématome (OPE) considérant que les HIV et les OPH sont des complications d'une HICs et que ce sont des biomarqueurs connus qui indiquent un risque plus élevé de mauvais pronostic⁷.

Durant ce projet, un total de 537 scans non segmentés a été utilisé pour la tâche prétexte *3D CPC* (tâche en amont), soit la portion d'apprentissage auto-supervisé, et 167 scans segmentés ont été utilisé pour la tâche de segmentation (tâche en aval), dont 40 (24%) ont servi uniquement à l'évaluation indépendante du modèle. Le jeu de données pour la segmentation a été divisé en fraction de 25%, 50% et 100% afin de pouvoir évaluer le gain en performance

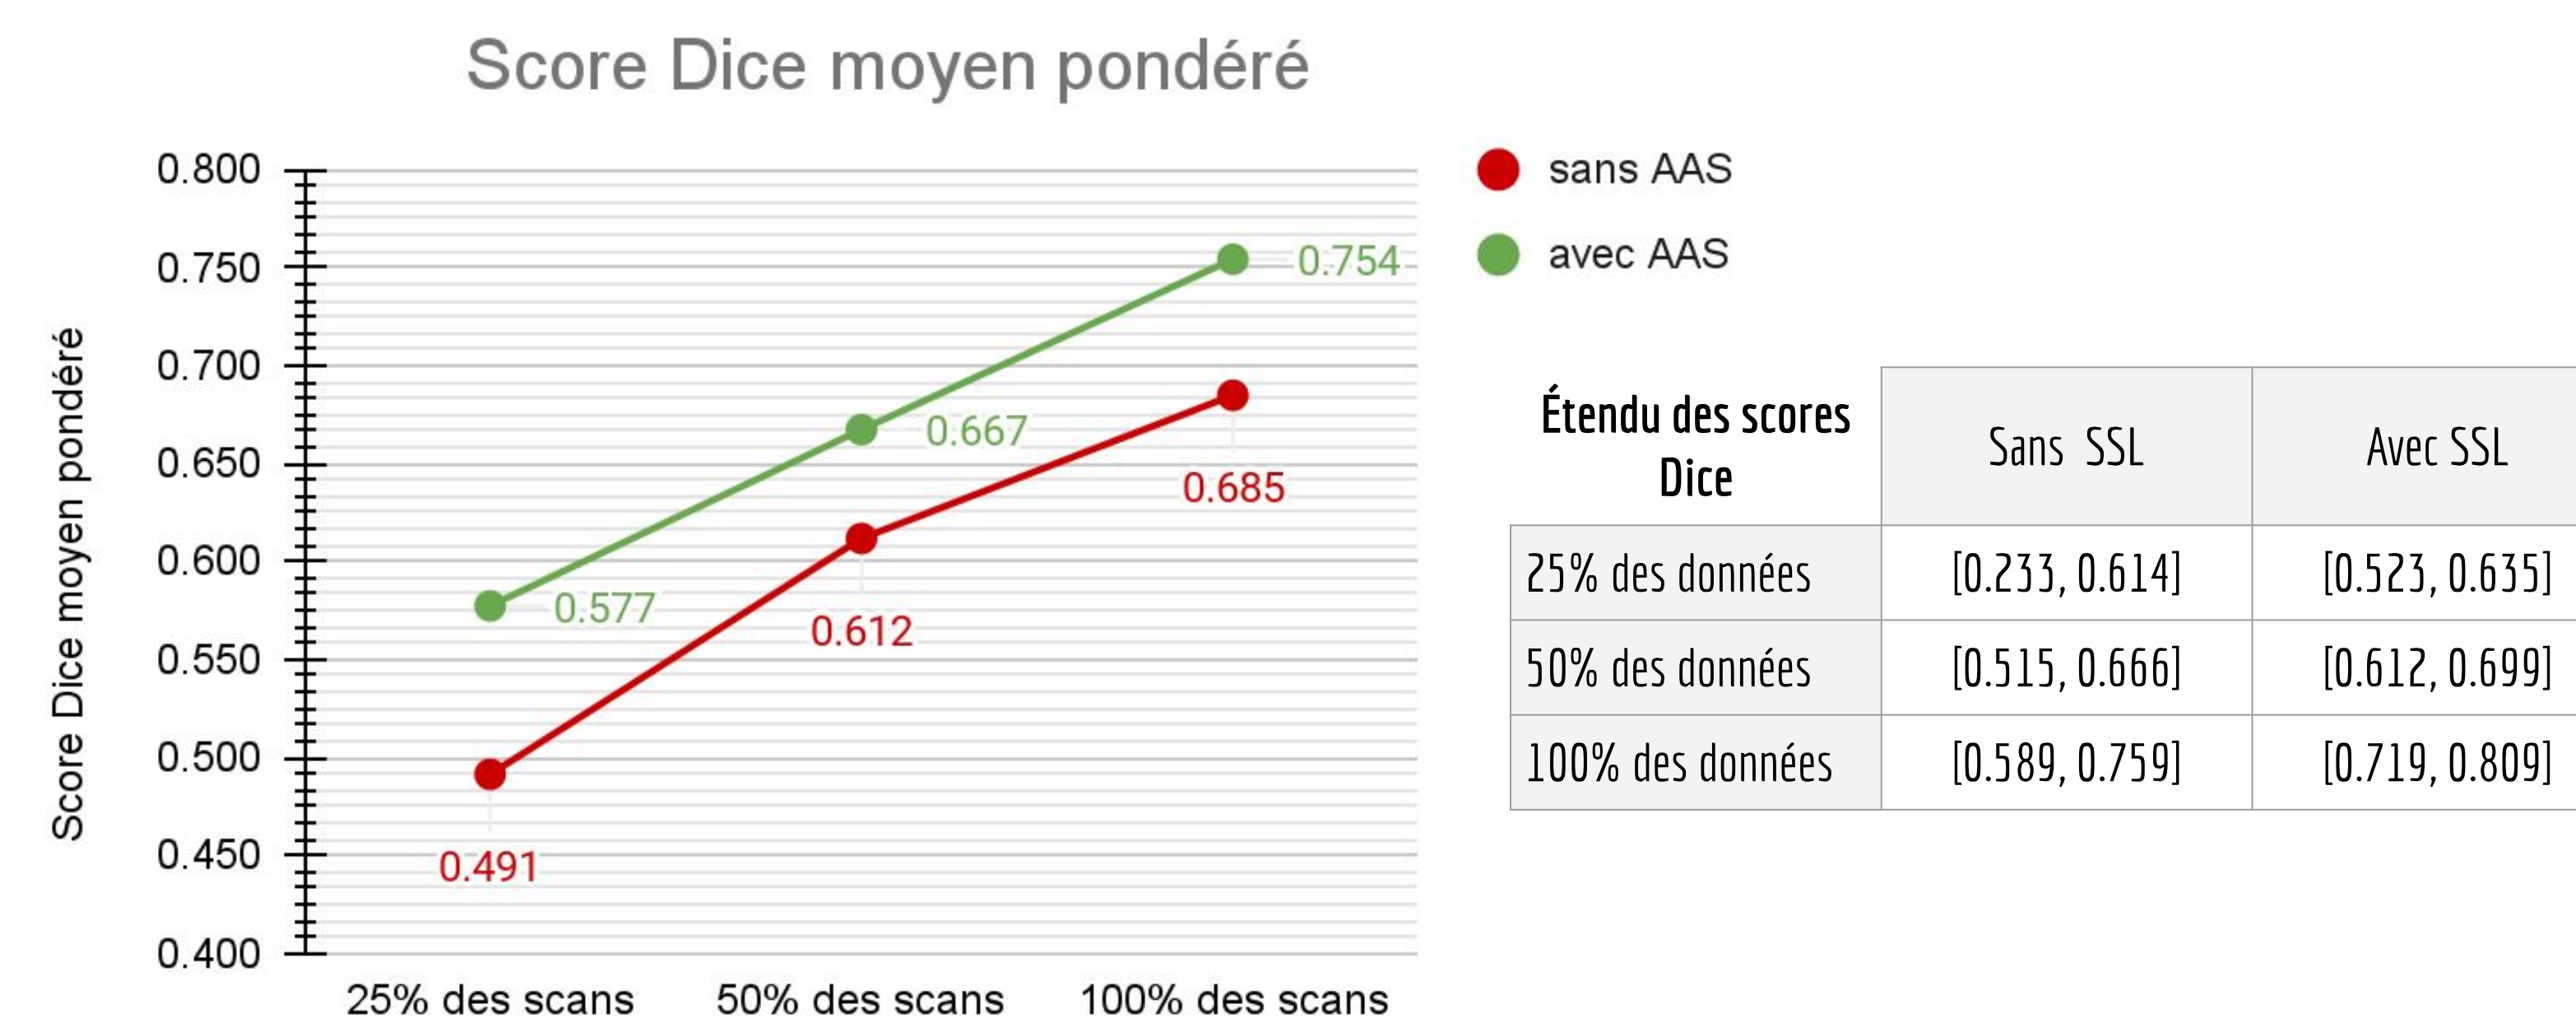


Figure 5: Score Dice moyen pondéré sur 5 itérations, avec et sans apprentissage auto-supervisé.

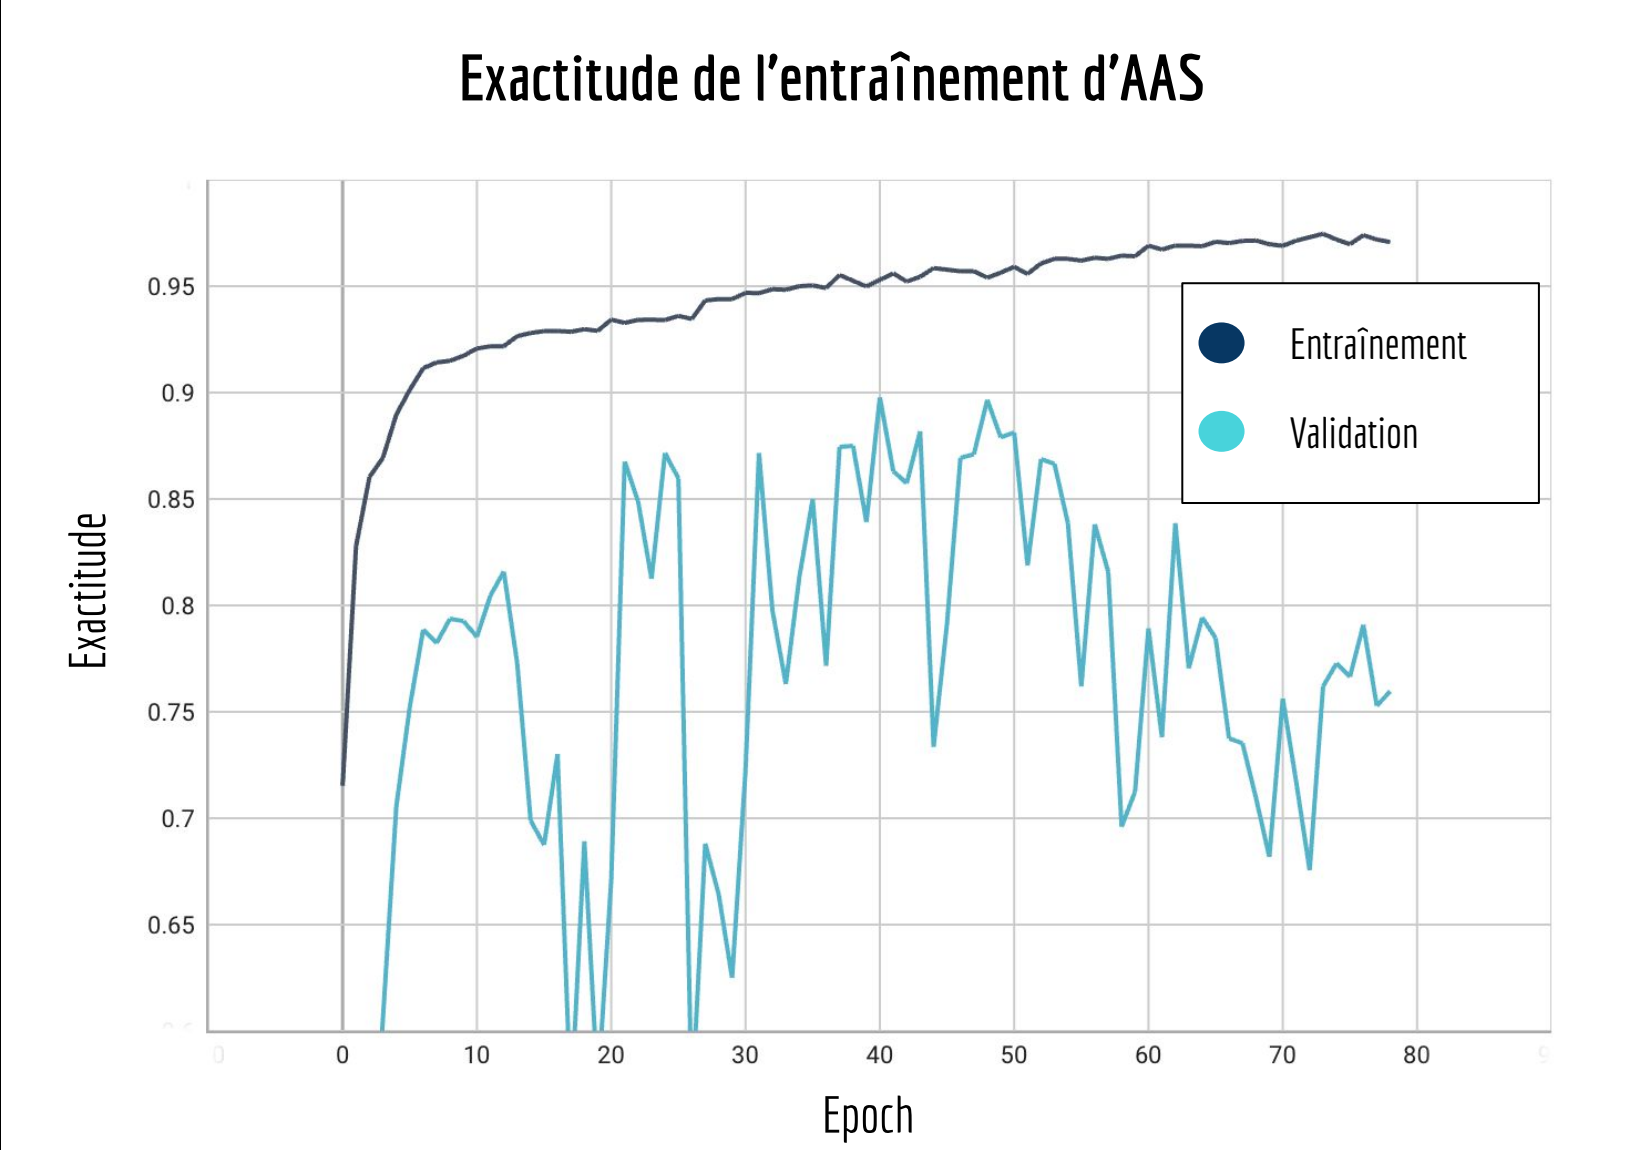


Figure 4: Exactitude d'entraînement et de validation par epoch.

selon la quantité de données disponible dans la tâche en aval. La tâche *3D CPC* est exécutée avec les paramètres par défaut pour 80 epochs. Durant l'entraînement, le but est de maximiser l'exactitude (*accuracy*) et de minimiser la perte (*loss*). La Figure 4 démontre l'exactitude pour l'entraînement et la validation au fil des epochs. La meilleure epoch s'avère la 40^e. Les poids de la 40^e epoch sont utilisés comme point de départ pour la tâche de segmentation d'HICs.

Résultats

La tâche de segmentation d'hémorragies intracérébrales, d'hémorragies intraventriculaires et d'oedème péri-hématome a été effectuée à l'aide du code de Taleb et al.⁶ qu'on a dû modifier légèrement. La tâche de segmentation a été exécutée pendant 100 epochs dont 5 de réchauffement, pour 5 itérations afin de prendre en compte l'effet partiellement aléatoire des modèles d'apprentissage profond. De plus, la tâche est exécutée pour trois proportions de données soit 100% des données annotées, 50% des données annotées et 25% des données annotées. Les résultats, soit les scores Dice moyens pondérés sur 5 itérations, sont montrés dans la Figure 5 accompagnés d'un tableau illustrant les valeurs minimales et maximales des scores Dice des essais. Pour l'entièreté des données d'entraînement, l'amélioration est de **6.9%**, pour la tranche de 50% des données, l'amélioration est de **5.5%** et pour 25% des données, l'amélioration est de **8.6%**. Ces résultats concordent avec ceux de Taleb et al. qui montrent que l'amélioration de performance est meilleure pour des plus petites quantités de données d'entraînement⁶.

Conclusion

La tâche de segmentation d'hémorragies intracérébrales, d'hémorragies intraventriculaires et d'oedème péri-hématome performe mieux avec l'apprentissage auto-supervisé. En somme, l'apprentissage auto-supervisé s'avère une approche intéressante pour les domaines dans lesquels l'étiquetage des données est un processus long et coûteux, tel que l'imagerie médicale. Lors de projets ultérieurs, on pourrait appliquer d'autres bibliothèques d'apprentissage auto-supervisé aux scans cérébraux afin de comparer leurs performances. De plus, on pourrait appliquer cette approche à la prédiction de progression hémorragique.

Références

- van Asch, C.J. et al. (2010) 'Incidence, case fatality, and functional outcome of intracerebral haemorrhage over time, according to age, sex, and ethnic origin: A systematic review and meta-analysis', *The Lancet Neurology*, 9(2), pp. 167-176. doi:10.1016/s1474-4422(09)70340-0.
- Flanders, A.E. et al. (2020) 'Construction of a machine learning dataset through collaboration: The RSNA 2019 Brain CT Hemorrhage Challenge', *Radiology: Artificial Intelligence*, 2(3). doi:10.1148/ryai.2020190211.
- Volbers, B. et al. (2011) 'Semi-automatic volumetric assessment of perihemorrhagic edema with computed tomography', *European Journal of Neurology*, 18(11), pp. 1323-1328. doi:10.1111/j.1468-1331.2011.03395.x.
- Akkus, Z. et al. (2020) 'Robust brain extraction tool for CT head images', *Neurocomputing*, 392, pp. 189-195. doi:10.1016/j.neucom.2018.12.085.
- Muschelli, J. (2020) 'A publicly available, high resolution, unbiased CT Brain Template', *Information Processing and Management of Uncertainty in Knowledge-Based Systems*, pp. 358-366. doi:10.1007/978-3-030-50153-2_27.
- Taleb, A., Loetzsch, W., Danz, N., Severin, J., Gaertner, T., Bergner, B., and Lippert, C. 2020. 3D Self-Supervised Methods for Medical Imaging. In *Advances in Neural Information Processing Systems* (pp. 18158-18172). Curran Associates, Inc..
- Chan, E. et al. (2015) 'Significance of intraventricular hemorrhage in acute intracerebral hemorrhage', *Stroke*, 46(3), pp. 653-658. doi:10.1161/strokeaha.114.008470.

Remerciements

Projet supporté par des subvention du Fonds de Recherche du Québec-Santé en partenariat avec la Fondation de l'Association des Radiologistes du Québec : subvention recherches en radiologie (299979) et support salarial du programme de chercheur-clinicien Junior 1 (311203), Fondation of the Radiological Society of North America - Seed Grant (RSD2122), Programme de support professoral du Département de radiologie, radio-oncologie et médecine nucléaire de l'Université de Montréal et fonds de démarrage du Centre de Recherche du CHUM, Fonds de démarrage du département de radiologie du CHUM, Fonds de démarrage du Centre de Recherche du CHUM.

Coordonnées: delphine.pilon@umontreal.ca