

Apport du Transfer Learning pour la segmentation automatique de lésions cérébrales radio-induites chez des patients atteints de glioblastome à partir d'un nombre restreint d'IRMs annotées

Auteurs : Thomas Coudert¹ (thomas.coudert10@gmail.com), Sophie Ancelet², Nadya Pyatigorskaya³, Lucia Nichelli³, Damien Ricard⁴, Dimitri Psimaras³, Marie-Odile Bernier², Michel Dojat¹, Florence Forbes⁵, Alan Tucholka⁶

Affiliations : ¹INSERM U1216, GIN ; ²IRSN, PSE-SANTE/SESANE/LEPID ; ³AP-HP Pitié-Salpêtrière & ICM ; ⁴HIA Percy & Centre Giovanni Borelli ; ⁵INRIA Grenoble Rhône-Alpes, Statify ; ⁶Pixyl

Résumé : Ces travaux sont issus du projet de recherche RAAI (Radiotherapy Assisted by AI, MIAI@Grenoble Alpes) dont l'objectif était de proposer un algorithme d'apprentissage automatique pour la segmentation d'hyper-intensités de la substance blanche à partir d'imageries par résonance magnétique (IRMs) cérébrales obtenues lors du suivi clinique de patients de la cohorte EPIBRAINRAD, traités par radio-chimiothérapie pour une tumeur cérébrale de haut grade. En effet, ces hyper-intensités constituent des biomarqueurs d'imagerie potentiellement associés à l'occurrence de leuco-encéphalopathies et de troubles neurocognitifs radio-induits. Aujourd'hui, les méthodes d'apprentissage profond constituent les meilleures techniques utilisées pour la segmentation d'images dans le domaine médical. Elles nécessitent néanmoins une importante quantité de données pour apprendre à réaliser cette tâche avec une certaine robustesse. Or, les données d'imagerie médicale publiques préalablement segmentées sont très peu nombreuses étant donné la difficulté et le temps requis pour un spécialiste pour annoter manuellement de telles images. Les méthodes d'apprentissage profond actuelles doivent donc apprendre à fonctionner avec cette faible quantité de données. Dans un premier temps, les algorithmes de segmentation 3D les plus performants actuellement - le réseau 3D Attention V-Net¹ - ont été appliqués de manière « classique », en collaboration avec la société Pixyl, en utilisant en entrée différents dataset de données publiques préalablement segmentées issues du challenge BraTS² et/ou des données de patients atteints de sclérose en plaques couplées à des acquisitions IRM 3D FLAIR issues de la cohorte EPIBRAINRAD. Dans un second temps, une méthode d'apprentissage par transfert (Transfer Learning) a été mise en œuvre : un premier modèle a été entraîné à partir de données pré-segmentées du challenge BraTS² puis les connaissances tirées de ce premier apprentissage ont été transférées lors de l'apprentissage de nouveaux modèles à partir de quelques IRMs cérébrales 3D de la cohorte EPIBRAINRAD. Plusieurs métriques ont été calculées afin de comparer la qualité des segmentations obtenues : le dice score, la sensibilité, la précision et la distance de Hausdorff. Les méthodes d'apprentissage classiques utilisées dans un premier temps n'ont pas permis d'obtenir des résultats de segmentation satisfaisants (**Figure 1**). En revanche, notre technique d'apprentissage par Transfer Learning a montré des résultats remarquables (**Figure 2**) en utilisant seulement 9 acquisitions IRM 3D FLAIR issues de la cohorte EPIBRAINRAD, lors de la phase d'entraînement et 11 acquisitions IRM 3D FLAIR lors de la phase de test. Ces travaux ont permis de mettre en évidence la supériorité et l'apport des méthodes de Transfer Learning par rapport aux méthodes d'apprentissage classiques dans un contexte où la quantité de données cliniques annotées à disposition est faible. Ils seront poursuivis dans le cadre du projet de recherche ANR **RADIO-AIDE** (**RADI**ation-induced neuro**O**toxicity assessed by spatio-temporal modelling combined with **Artificial Intelligence** after brain ra**D**ioth**E**rapy) (2022-2026).




Figure 1 : Exemple de prédiction réalisée par un algorithme de Deep Learning entraîné "classiquement" sur seulement 9 images IRM 3D FLAIR




Figure 2 : Résultats de prédictions d'un modèle entraîné par Transfer Learning. Le modèle est pré-entraîné sur des données issue du challenge BraTS 2016-2017 puis entraîné sur seulement 9 images de la cohorte d'intérêt.

Bibliographie :

¹ Fausto Milletari, Nassir Navab, Seyed-Ahmad Ahmadi (2016) V-net : **Fully convolutional neural networks for volumetric medical image segmentation**. CoRR, abs/1606.04797

² B.H. Menze et al. (2015) **The multimodal brain tumor image segmentation benchmark (brats)**. IEEE Transactions on Medical Imaging. 34(10) :1993-2024