



Dosimétrie portale de non-transit par apprentissage de réseaux de neurones artificiels

Lucas Dal Bosco^{1,2,4}, Xavier Franceries^{3,4}, Blandine Romain¹, François Smekens¹, François Husson¹ & Marie Véronique Le Lann^{2,3}

¹DOSIsoft, Cachan, France

²LAAS-CNRS, Toulouse, France

³INSERM, Toulouse, France

⁴INSA, Toulouse, France

Résumé

Contexte : Les applications de l'apprentissage automatique et de l'apprentissage profond, en tant que branche de l'intelligence artificielle dans le domaine de la radiothérapie externe ont connu une croissance rapide au cours des dernières années [1]. Dans le cadre de l'assurance qualité spécifique au patient, ces méthodes permettent d'envisager la généralisation de l'automatisation des procédés d'assurance qualité [2], [3], [4] et aussi une approche algorithmique nouvelle pour le calcul des distributions de dose, notamment depuis l'imagerie portale pour la vérification prétraitement [5], [6], [7].

Objectif : Le contrôle prétraitement repose sur la comparaison d'une distribution de dose prédite en conditions idéales avec une image dosimétrique convertie à partir d'une image portale acquise en non-transit. Ce travail a pour objectif de proposer le calcul de prédiction de la dose et de la conversion en dose de l'image portale mesurée par une méthode d'apprentissage profond dédiée.

Matériel et méthodes : Pour le moteur de prédiction, un réseau de neurones convolutif de type U-net a été développé afin de prédire des distributions de dose absolue à partir des données de la balistique de traitement. Pour le moteur de conversion, un second U-net architecturalement similaire a été développé afin de convertir, dans les mêmes conditions géométriques, l'image portale acquise en distribution de dose absolue.

Les images dosimétriques fournies en tant que sorties idéales des deux U-nets sont issues du modèle analytique de prédiction en dose de la solution EPIbeam (DOSIsoft). Dans le cas du modèle de prédiction, des masques de fluence incidente totale par segment ont été calculés puis utilisés comme données d'entrée. Pour le moteur de conversion, les images fournies en entrée ont été acquises au moyen d'un imageur portal au silicium amorphe (aSi-EPID iView GT, Elekta) et un faisceau de 6 MV FF (linac Synergy, Elekta). Les deux modèles proposés ont été entraînés sur sept plans de traitement de type RCMI de localisations tumorales diverses et validés par l'intermédiaire d'une procédure de validation-croisée en cinq plis. 186 faisceaux ont servi pour l'apprentissage du modèle de conversion. Pour l'entraînement du modèle de prédiction, 2271 segments ont été utilisés.

Pour les deux implémentations, la nouveauté réside dans l'ajout au sein des modèles d'une couche neuronale non-entraînable appelée True Dose Modulation. L'ajout de cette couche additionnelle couplée au transfert d'apprentissage a pour objectif de remédier à la problématique d'invariance spatiale des réseaux de neurones convolutifs et ainsi, de permettre aux modèles une fois entraînés, de restituer la distribution spatiale de la dose dans l'eau.

Résultats : Un ensemble de 29 faisceaux et de 236 segments de type RCMI ont été utilisés pour l'évaluation des modèles finaux. Des moyennes d'indice γ et d'agrément ($2\%-2\text{mm} > 10\%D_{\max}$) de 0,11 ($\pm 0,02$), 99,98



($\pm 0,17$) % et de $0,24 (\pm 0,04)$, $99,29 (\pm 0,7)$ % ont respectivement été obtenues par le modèle de prédiction et le modèle de conversion. Sur les ensembles de données de contrôle, des variations d'agrément de l'indice γ de 0,21 % et de 0,6% entre les U-nets seuls et couplés à leur couche True Dose Modulation ont respectivement été obtenues par le modèle de prédiction et le modèle de conversion. L'ajout de la couche True Dose Modulation couplée au transfert d'apprentissage procure une amélioration significative des résultats.

Conclusion : Une méthode originale de dosimétrie de non-transit basée sur les méthodes d'apprentissage profond a été développée. Les résultats satisfaisants obtenus demandent à être vérifiés avec d'autres faisceaux de radiothérapie (énergie, mode de fluence).

Références

- [1] B. Sahiner *et al.*, « Deep learning in medical imaging and radiation therapy », *Med. Phys.*, vol. 46, n° 1, p. e1- e36, janv. 2019, doi: 10.1002/mp.13264.
- [2] J. N. K. Carlson, J. M. Park, S.-Y. Park, J. I. Park, Y. Choi, et S.-J. Ye, « A machine learning approach to the accurate prediction of multi-leaf collimator positional errors », *Phys. Med. Biol.*, vol. 61, n° 6, p. 2514- 2531, mars 2016, doi: 10.1088/0031-9155/61/6/2514.
- [3] G. Valdes, R. Scheuermann, C. Y. Hung, A. Olszanski, M. Bellerive, et T. D. Solberg, « A mathematical framework for virtual IMRT QA using machine learning », *Med. Phys.*, vol. 43, n° 7, p. 4323, juill. 2016, doi: 10.1118/1.4953835.
- [4] G. Guidi *et al.*, « A support vector machine tool for adaptive tomotherapy treatments: Prediction of head and neck patients criticalities », *Phys. Medica PM Int. J. Devoted Appl. Phys. Med. Biol. Off. J. Ital. Assoc. Biomed. Phys. AIFB*, vol. 31, n° 5, p. 442- 451, juill. 2015, doi: 10.1016/j.ejmp.2015.04.009.
- [5] G. Kalantzis, L. A. Vasquez-Quino, T. Zalman, G. Prax, et Y. Lei, « Toward IMRT 2D dose modeling using artificial neural networks: a feasibility study », *Med. Phys.*, vol. 38, n° 10, p. 5807- 5817, oct. 2011, doi: 10.1118/1.3639998.
- [6] S. R. Mahdavi, M. Bakhshandeh, A. Rostami, et A. J. Arfaee, « 2D Dose Reconstruction by Artificial Neural Network for Pretreatment Verification of IMRT Fields », *J. Med. Imaging Radiat. Sci.*, p. 7, avr. 2018.
- [7] F. Chatrie, X. Franceries, et M. V. Le Lann, « Deep learning for regression problem applied to radiotherapy pre-treatment verification », 2019.