
Génération de CT synthétiques dirigée par la physique pour la radiothérapie adaptative

Michael Dagher^{*1} and Dimitri Reynard^{*†2}

¹Synchrotron Radiation for Biomedicine = Rayonnement SynchroTRON pour la Recherche Biomédicale
– Institut National de la Santé et de la Recherche Médicale, Université Grenoble Alpes – France

²Groupe Hospitalier Mutualiste de Grenoble [France] – Groupe Hospitalier Mutualiste de Grenoble
[France] – France

Résumé

Introduction : La radiothérapie adaptative (ART) en ligne repose sur l'acquisition quotidienne d'images Cone-Beam CT (CBCT) permettant le recalcul de dose à chaque séance 1. Toutefois, les CBCT présentent des limitations physiques (bruit, diffusion, durcissement du faisceau, artefacts de reconstruction) ainsi que des valeurs pseudo-unités Hounsfield 2, rendant la réévaluation dosimétrique plus incertaine qu'un calcul réalisé sur un CT dosimétrique. Des approches récentes utilisent le deep learning pour générer des CT synthétiques (sCT) depuis les CBCT 3, entraînant un réseau de neurones (RNN) à transformer l'image. Un recalage déformable (DIR) est généralement appliqué pour apparier le CT de planification (pCT) au CBCT. Cependant, le DIR est un problème mathématique mal posé, susceptible d'introduire des déformations non-anatomiques. Pour contourner cette limitation, notre approche déterministe fondée sur des modèles physiques dégrade volontairement le pCT pour générer un "dirty CT" (diCT). Cela constitue un jeu de données appariées pCT/diCT, sans biais anatomique, pour entraîner le RNN à apprendre la transformation inverse.

Matériel et méthodes : L'objectif est de transformer les pCT en diCT en agissant directement dans l'espace des projections. À partir du pCT, des projections sont générées selon une géométrie CBCT half-fan 3D reproduite avec le package TIGRE. Le "salissage" simule directement sur ces projections les phénomènes altérant le CBCT réel : diffusion, durcissement du faisceau, aliasing, sous-échantillonnage et mouvement patient. Ces altérations paramétrables sont appliquées avant reconstruction par l'algorithme FDK. Les caractéristiques des diCT sont comparées à celles de CBCT réels dans différentes structures anatomiques. Des histogrammes volumiques sont extraits et les écarts entre distributions sont quantifiés via la divergence de Jensen-Shannon (JSD) et la distance de Wasserstein (WD) pour identifier les paramètres optimaux.

Résultats : Validé sur 10 patients, le pipeline réduit considérablement l'écart statistique absolu entre le pCT et le CBCT clinique. Grâce à l'optimisation paramétrique des altérations physiques, la distance de Wasserstein (WD) moyenne passe d'une erreur initiale de $24,4 \pm 6,1$ UH à une distance finale de $14,4 \pm 3,9$ UH. Simultanément, la divergence de Jensen-Shannon (JSD) diminue, passant d'une base de $0,096 \pm 0,021$ à $0,015 \pm 0,004$. La forte diminution de ces métriques et la réduction de leurs écarts-types prouvent que la distribution des intensités du diCT mime fidèlement celle du CBCT clinique, garantissant une simulation robuste et

^{*}Intervenant

[†]Auteur correspondant: dimitri.reynard@ghm-grenoble.fr

indépendante de l'anatomie du patient.

Conclusions : La modélisation physique de la dégradation d'un pCT en diCT permet de générer des paires d'entraînement sans biais anatomique. Dans ce cadre, un RNN peut apprendre la transformation inverse et produire des sCT exploitables pour le recalcul de dose en radiothérapie adaptative.

References:

1. Schwartz, D. L. *et al.* Adaptive radiotherapy for head and neck cancer - Dosimetric results from a prospective clinical trial. *Radiotherapy and Oncology* **106**, 80–84 (2013).
2. Schulze, R. *et al.* Artefacts in CBCT: A review. *Dentomaxillofacial Radiology* vol. 40 265–273 Preprint at <https://doi.org/10.1259/dmfr/30642039> (2011).
3. Liang, X. *et al.* Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy. *Phys. Med. Biol.* **64**, (2019).

Mots-Clés: Radiothérapie adaptative, Cone, Beam CT, CT synthétique, Deep Learning, Modélisation physique