



Activitatea A2.1 - *Organizarea și desfășurarea programelor de învățare la locul de muncă (stagii de practică) pentru studenții de la facultățile din cadrul proiectului, prevăzute în curriculum-ul obligatoriu*

Pregătirea de propuneri pentru proiectele studenților care efectuează stagiile de practică în domeniul radioterapiei, folosind metode de tip Machine Learning

Justificarea utilizării metodelor de tip machine learning în radioterapie

Radioterapia modernă este un proces clinic complex, dependent de imagistică medicală, conturarea volumelor țintă și a organelor la risc, planificarea dozei, verificarea calității și adaptarea tratamentului la modificările anatomice ale pacientului. În acest context, metodele de tip machine learning, în special deep learning, sunt justificate deoarece pot exploata volume mari de date clinice – imagini CT/MRI/CBCT, contururi, distribuții de doză, planuri anterioare și date de tratament – pentru a sprijini decizii mai rapide, mai consistente și mai personalizate. Literatura de specialitate descrie utilizarea machine learning în radioterapie pentru segmentare automată, planificare, predicția dozei, radiomică, predicția răspunsului și optimizarea fluxurilor clinice.

Un prim argument major este reducerea variabilității și a timpului necesar pentru conturarea manuală. Delimitarea volumelor țintă și a organelor la risc este una dintre etapele cele mai consumatoare de timp și poate varia între specialiști. Modelele de deep learning pot genera contururi inițiale care sunt ulterior verificate și corectate de medicul radioterapeut, accelerând procesul fără a elimina controlul clinic. Studiile privind auto-segmentarea în cancer pulmonar, cancer cervical, cap și gât sau alte localizări arată că aceste metode pot îmbunătăți eficiența fluxului de lucru și pot contribui la o mai bună standardizare a planificării.

Un al doilea argument este îmbunătățirea planificării tratamentului. Planificarea radioterapiei presupune găsirea unui compromis între acoperirea optimă a tumorii și protejarea țesuturilor sănătoase. Metodele machine learning pot învăța din planuri clinice anterioare pentru a estima distribuții de doză, a propune configurații de tratament sau a accelera optimizarea planului. Astfel, ele pot reduce numărul de iterații manuale, pot susține consistența între cazuri similare și pot ajuta la identificarea unor soluții de planificare mai apropiate de bunele practici instituționale.

Un al treilea argument este rolul în radioterapia adaptivă. Anatomia pacientului se poate modifica pe parcursul tratamentului, iar poziția tumorii și a organelor la risc poate varia între fracții. În radioterapia adaptivă, este necesară recalcularea rapidă a conturilor, a distribuției de doză și, uneori, a planului de tratament. Modelele bazate pe deep learning pot susține această





etapă prin segmentare rapidă, predicție de doză și automatizarea unor componente ale fluxului adaptiv, ceea ce este important mai ales în scenariile în care timpul disponibil pentru decizia clinică este limitat.

Utilizarea machine learning este justificată și prin potențialul de personalizare a tratamentului. Modelele predictive pot integra informații imagistice, clinice și dozimetrice pentru a estima răspunsul la tratament, riscul de toxicitate sau probabilitatea de recurență. Aceste estimări pot contribui la o radioterapie mai individualizată, în care tratamentul nu este optimizat doar geometric și fizic, ci și în raport cu profilul biologic și clinic al pacientului. Totuși, aceste aplicații trebuie validate riguros înainte de integrarea în decizii clinice.

În același timp, folosirea machine learning în radioterapie trebuie abordată prudent. Modelele nu trebuie tratate ca înlocuitori ai medicului, fizicianului medical sau dosimetristului, ci ca instrumente de suport decizional. Implementarea clinică trebuie să includă validare locală, testare externă, monitorizarea performanței, verificarea biasului, trasabilitate, protocoale clare de quality assurance și menținerea responsabilității umane asupra deciziei finale. Din acest motiv, justificarea utilizării machine learning în radioterapie nu este doar tehnologică, ci și organizațională: aceste metode pot crește eficiența, consistența și personalizarea tratamentului, dar numai într-un cadru clinic controlat, verificabil și orientat spre siguranța pacientului.

Mai jos este dată o listă de 18 titluri bibliografice publicate în jurnale open science, astfel încât studenții să aibă acces la lucrările respective.

1. Machine Learning in Radiation Oncology: Opportunities, Requirements, and Needs, Feng M., Valdes G., Dixit N., Solberg T.D., *Frontiers in Oncology*, vol. 8, articol 110, DOI: <https://doi.org/10.3389/fonc.2018.00110>
2. Deep Learning: A Review for the Radiation Oncologist, Boldrini L., Bibault J.-E., Masciocchi C., Shen Y., Bittner M.-I., *Frontiers in Oncology*, vol. 9, articol 977, DOI: <https://doi.org/10.3389/fonc.2019.00977>
3. A Review on Application of Deep Learning Algorithms in External Beam Radiotherapy Automated Treatment Planning, Wang M., Zhang Q., Lam S., Cai J., Yang R., *Frontiers in Oncology*, vol. 10, articol 580919, DOI: <https://doi.org/10.3389/fonc.2020.580919>
4. The Application and Development of Deep Learning in Radiotherapy: A Systematic Review, Huang D., Bai H., Wang L., Hou Y., Li L., Xia Y., Yan Z., Chen W., Chang L., Li W., *Technology in Cancer Research & Treatment*, vol. 20, articol 15330338211016386, DOI: <https://doi.org/10.1177/15330338211016386>
5. Training and Validation of Deep Learning-Based Auto-Segmentation Models for Lung





- Stereotactic Ablative Radiotherapy Using Retrospective Radiotherapy Planning Contours, Wong J., Huang V., Giambattista J.A., Teke T., Kolbeck C., Giambattista J., Atrchian S., *Frontiers in Oncology*, vol. 11, articol 626499, DOI: <https://doi.org/10.3389/fonc.2021.626499>
6. Implementation of deep learning-based auto-segmentation for radiotherapy planning structures: a workflow study at two cancer centers, Wong J., Huang V., Wells D., Giambattista J., Giambattista J., Kolbeck C., Otto K., Saibishkumar E.P., Alexander A., *Radiation Oncology*, vol. 16, articol 101, DOI: <https://doi.org/10.1186/s13014-021-01831-4>
7. Deep Learning Improved Clinical Target Volume Contouring Quality and Efficiency for Postoperative Radiation Therapy in Non-small Cell Lung Cancer, Bi N., Wang J., Zhang T., Chen X., Xia W., Miao J., Xu K., Wu L., Fan Q., Wang L., Li Y., Zhou Z., Dai J., *Frontiers in Oncology*, vol. 9, articol 1192, DOI: <https://doi.org/10.3389/fonc.2019.01192>
8. Evaluation of deep learning-based auto-segmentation algorithms for delineating clinical target volume and organs at risk involving data for 125 cervical cancer patients, Wang Z., Chang Y., Peng Z., Lv Y., Shi W., Wang F., Pei X., Xu X.G., *Journal of Applied Clinical Medical Physics*, vol. 21, nr. 12, pp. 272–279, DOI: <https://doi.org/10.1002/acm2.13097>
9. Clinical application and improvement of a CNN-based autosegmentation model for clinical target volumes in cervical cancer radiotherapy, Chang Y., Wang Z., Peng Z., Zhou J., Pi Y., Xu X.G., Pei X., *Journal of Applied Clinical Medical Physics*, vol. 22, nr. 11, pp. 115–125, DOI: <https://doi.org/10.1002/acm2.13440>
10. Deep learning-based auto-segmentation of clinical target volumes for radiotherapy treatment of cervical cancer, Ma C.-Y., Zhou J.-Y., Xu X.-T., Guo J., Han M.-F., Gao Y.-Z., Du H., Stahl J.N., Maltz J.S., *Journal of Applied Clinical Medical Physics*, vol. 23, nr. 2, articol e13470, DOI: <https://doi.org/10.1002/acm2.13470>
11. Clinical evaluation of deep learning-based clinical target volume three-channel auto-segmentation algorithm for adaptive radiotherapy in cervical cancer, Ma C.-Y., Zhou J.-Y., Xu X.-T., Qin S.-B., Han M.-F., Cao X.-H., Gao Y.-Z., Xu L., Zhou J.-J., Zhang W., Jia L.-C., *BMC Medical Imaging*, vol. 22, articol 123, DOI: <https://doi.org/10.1186/s12880-022-00851-0>
12. RefineNet-based 2D and 3D automatic segmentations for clinical target volume and organs at risks for patients with cervical cancer in postoperative radiotherapy, Xiao C., Jin J., Yi J., Han C., Zhou Y., Ai Y., Xie C., Jin X., *Journal of Applied Clinical Medical Physics*, vol. 23, nr. 7, articol e13631, DOI: <https://doi.org/10.1002/acm2.13631>
13. Three-dimensional deep neural network for automatic delineation of cervical cancer in planning computed tomography images, Ding Y., Chen Z., Wang Z., Wang X., Hu D., Ma P., Ma C., Wei W., Li X., Xue X., Wang X., *Journal of Applied Clinical Medical Physics*, vol. 23, nr. 4, articol e13566, DOI: <https://doi.org/10.1002/acm2.13566>
14. Automated clinical target volume delineation using deep 3D neural networks in radiation therapy of Non-small Cell Lung Cancer, Xie Y., Kang K., Wang Y., Khandekar M.J., Willers H.,





Keane F.K., Bortfeld T.R., Physics and Imaging in Radiation Oncology, vol. 19, pp. 131–137, DOI: <https://doi.org/10.1016/j.phro.2021.08.003>

15. Boosting radiotherapy dose calculation accuracy with deep learning, Xing Y., Zhang Y., Nguyen D., Lin M.-H., Lu W., Jiang S., Journal of Applied Clinical Medical Physics, vol. 21, nr. 8, pp. 149–159, DOI: <https://doi.org/10.1002/acm2.12937>

16. TrDosePred: A deep learning dose prediction algorithm based on transformers for head and neck cancer radiotherapy, Hu C., Wang H., Zhang W., Xie Y., Jiao L., Cui S., Journal of Applied Clinical Medical Physics, vol. 24, nr. 7, articol e13942, DOI: <https://doi.org/10.1002/acm2.13942>

17. Automated plan generation for prostate radiotherapy patients using deep learning and scripted optimization, Church C., Yap M., Bessrouer M., Lamey M., Granville D., Physics and Imaging in Radiation Oncology, vol. 32, articol 100641, DOI: <https://doi.org/10.1016/j.phro.2024.100641>

18. Closing the gap in plan quality: Leveraging deep-learning dose prediction for adaptive radiotherapy, Domal S.J., Maniscalco A., Visak J., Dohopolski M., Moon D., Avkshtol V., Nguyen D., Jiang S., Sher D., Lin M.H., Journal of Applied Clinical Medical Physics, vol. 26, nr. 5, articol e70045, DOI: <https://doi.org/10.1002/acm2.70045>

Întocmit,
Prof. dr. Vasile Chiș
Expert practică

