

zahrnuty i biologické ukazatele, je možné dosahovat lepší predikční schopnosti NTCP modelování (12, 13).

Umělá inteligence (AI) zejména v podobě algoritmů strojového učení (Machine Learning – ML) je v radiační onkologii využívána v mnoha oblastech – pro konturaci cílových objemů, při plánování léčby, v metodách fyzikálního zajištění kvality i v modelování odpovědi nádoru na léčbu a modelování nežádoucích účinků léčby (13). Strojové učení, které je považováno v jistém smyslu za podмноžinu metod umělé inteligence (i když se tyto pojmy často zaměňují), představuje jednu z nejprogresivnějších a nejpoužívanějších metod pro zpracování a analýzu velkých objemů dat. Výpočetní systém se naučí zpracovávat určitý typ dat a poté, co je potvrzena správnost využívaných algoritmů, může počítač zpracovávat data samostatně vysokou rychlostí (14, 15). Moderní radiobiologické nástroje s využitím strojového učení umožňují využití heterogenních dat k predikci individuální pravděpodobnosti toxicity po záření – klinické údaje, kvalitativní parametry z 3D dávkové distribuce (dosiometrické znaky), biologické znaky, konturace a anatomické 3D charakteristiky struktur na snímcích zobrazovacích metod (radiometrické znaky) (16, 17, 18).

Jako příklad je možné uvést analýzy zátěže slinných žláz při radioterapii hlavy a krku. Po ozáření dochází ve slinných žlázách ke ztrátě buněk i sekrečních granul a k atrofii žlázy, což vede k redukci tvorby slin. Akutní a chronická xerostomie významně ovlivňují kvalitu života pacienta po léčbě, a proto je šetření slinných žláz jedním ze základních pravidel správného plánování radioterapie v oblasti hlavy a krku. Smrštění příušních a submandibulárních žláz během radioterapie a v následujícím období bylo potvrzeno výzkumy, přičemž míra zmenšení žláz byla spojena se střední dávkou na tyto žlázy (19). Byla však publikována řada radiobiologických modelů, které ukázaly silnější prediktivní význam dávky na konkrétní část příušní žlázy, kde je vyšší zastoupení kmenových buněk (20), nebo význam strmosti spádu dávky v oblasti parotidy (21) pro rozvoj xerostomie po ozáření. I výsledky dalších radiobiologických výzkumů s využitím radiomiky a strojového učení podporují prostorový vztah dávky a účinku v oblasti příušních žláz (12, 13, 16), ale pro ověření těchto skutečností a vývoj spolehlivého radiobiologického modelu by bylo třeba provést rozsáhlejší studii (22, 23).

Prediktivní modely založené na principech ML mohou prohloubit pochopení poradiační toxicity a do budoucna mohou přispět k in-

dividualizaci léčebného přístupu specificky pro konkrétního pacienta k dosažení maximálního léčebného přínosu a minimalizace toxicity (13).

Závěr

Radioterapie patří k neúčinnějším modalitám onkologické léčby, ale její využití je zatíženo rizikem rozvoje nežádoucích účinků. Závažnost akutních a pozdních projevů je variabilní a závisí na biologických a klinických charakteristikách, dávkovém zatížení rizikových struktur a radiometrických faktorech. Pravděpodobnost toxicity zdravých tkání je popisována radiobiologickými nástroji a modely – v praxi je rozšířený projekt QUANTEC a radiobiologické modelování na podkladě EUD a NTCP. Dosud publikované radiometrické studie s nástroji umělé inteligence zpracovávajícími pestrou škálu heterogenních znaků poskytují slibné výsledky, jež by mohly vést do budoucna k individualizaci léčebných postupů na podkladě podrobné analýzy rizik. Dostupné údaje jsou však zatím limitované a před klinickou implementací radiobiologických modelů pro predikci toxicity radioterapie by bylo třeba ověření na rozsáhlejších datasetech a v kontextu klinických studií.

LITERATURA

1. Šlampa P, et al. Radiační onkologie. Praha: Maxdorf; 2021.
2. Krupa P. Jak zvládnout nežádoucí účinky radioterapie. Onkologie. 2020;14(Suppl. C):24-29.
3. Hynková L, Doleželová H. Nežádoucí účinky radioterapie a podpůrná léčba u radioterapie nádorů hlavy a krku. Onkologie. 2008;2(2):88-90.
4. King SN, Dunlap NE, Tennant PA, et al. Pathophysiology of Radiation-Induced Dysphagia in Head and Neck Cancer. Dysphagia. 2016;31(3):339-351.
5. Lohynská R, Jirkovská M, Krátká Z. Časový faktor v radikální radioterapii nádorů hlavy a krku. Postgraduální medicína. 2020;2:115-120.
6. Pechačová Z, Lohynská R. Klinická aplikace principů časového faktoru v radioterapii při kompenzaci přerušení ozařovací série. Klin Onkol. 2021;34(6):455-462.
7. Lohynská R, Pechačová Z, Mazaně E, et al. Radioterapie a radiosenzitivní syndromy u mutací genů reparace DNA. Klin Onkol. 2022;35(2):119-127.
8. Emami B, Lyman J, Brown A, et al. Tolerance of normal tissue to therapeutic irradiation. Int J Radiat Oncol Biol Phys. 1991;21(1):109-122.
9. Kehwar TS. Analytical approach to estimate normal tissue complication probability using best fit of normal tissue tolerance doses into the NTCP equation of the linear quadratic model. J Cancer Res Ther. 2005;1(3):168-179.
10. Bentzen SM, Constine LS, Deasy JO, et al. Quantitative

- Analyses of Normal Tissue Effects in the Clinic (QUANTEC): an introduction to the scientific issues. Int J Radiat Oncol Biol Phys. 2010;76(3 Suppl):S3-9.
11. Marks LB, Yorke ED, Jackson A, et al. Use of normal tissue complication probability models in the clinic. Int J Radiat Oncol Biol Phys. 2010;76(3 Suppl):S10-19.
12. Beetz I, Schilstra C, Burlage FR, et al. Development of NTCP models for head and neck cancer patients treated with three-dimensional conformal radiotherapy for xerostomia and sticky saliva: the role of dosimetric and clinical factors. Radiother Oncol. 2012;105(1):86-93.
13. Sheikh K, Lee SH, Cheng Z, et al. Predicting acute radiation induced xerostomia in head and neck Cancer using MR and CT Radiomics of parotid and submandibular glands. Radiation Oncology. 2019;14(1).
14. Isaksson LJ, Pepa M, Zaffaroni M, et al. Machine Learning-Based Models for Prediction of Toxicity Outcomes in Radiotherapy. Front Oncol 2020;10.
15. IBM Data and AI team. AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the difference? Available from: <https://www.ibm.com/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>. (cited 26.11.2023).
16. Gabrys HS, Buettner F, Sterzing F, et al. Design and selection of machine learning methods using radiomics and dosimetrics for normal tissue complication probability modeling

- of xerostomia. Front Oncol. 2018;8:35.
17. Chinnery T, Arifin A, Tay KY, et al. Utilizing Artificial Intelligence for Head and Neck Cancer Outcomes Prediction From Imaging. Canadian Association of Radiologists Journal. 2021;72(1):73-85.
18. Bang C, Bernard G, Le WT, et al. Artificial intelligence to predict outcomes of head and neck radiotherapy. Clin Transl Radiat Oncol. 2023;39:100590.
19. Wu VWC, Leung KY. A Review on the Assessment of Radiation Induced Salivary Gland Damage After Radiotherapy. Front Oncol. 2019;9:1090.
20. Van Luick P, Pringle S, Deasy JO, et al. Sparing the region of the salivary gland containing stem cells preserves saliva production after radiotherapy for head and neck cancer. Sci Transl Med. 2015;7:305ra147.
21. Buettner F, Miah AB, Gulliford SL, et al. Novel approaches to improve the therapeutic index of head and neck radiotherapy: an analysis of data from the PARSPORT randomized phase III trial. Radiother Oncol. 2012;103:82-87.
22. Rancati T, Fiorino C. Modelling radiotherapy side effects: practical applications for planning optimisation. Boca Raton, CRC Press/Taylor & Francis Group; 2019.
23. Carbonara R, Bonomo P, Di Rito A, et al. Investigation of Radiation-Induced Toxicity in Head and Neck Cancer Patients through Radiomics and Machine Learning: A Systematic Review. J Oncol. 2021;2021:5566508.