

Forum 2024 · 39:264–268
<https://doi.org/10.1007/s12312-024-01353-6>
 Online publiziert: 8. August 2024
 © The Author(s), under exclusive licence to
 Springer Medizin Verlag GmbH, ein Teil von
 Springer Nature 2024



In diesem Beitrag

- Bildgebung und adaptive Strahlentherapie
- Konturierung von Risikoorganen
- Konturierung des Zielvolumens
- Prognose- und Prädiktionsmodelle



**PD Dr. med.
Alexander
Rühle, MHBA**
 Universitätsklinikum
 Leipzig, Leipzig

© A. Rühle



QR-Code scannen & Beitrag online lesen

Künstliche Intelligenz in der Strahlentherapie

Alexander Rühle^{1,2}

¹ Klinik und Poliklinik für Strahlentherapie, Universitätsklinikum Leipzig, Leipzig, Deutschland

² Mitteldeutsches Krebszentrum (CCCG), Partnerstandort Leipzig, Leipzig, Deutschland

Zusammenfassung

Hintergrund: Die Strahlentherapie ist eine zentrale Therapiesäule in der Krebstherapie; etwa die Hälfte aller Krebspatienten erhält während der Erkrankung eine Strahlentherapie. Bei all diesen Schritten kann künstliche Intelligenz (KI) eingesetzt werden, um die Präzision, Effizienz und Personalisierung der Strahlentherapie zu erhöhen.

Ziel: Diese Arbeit präsentiert eine kritische Bewertung der aktuellen Verwendung von KI in der Strahlentherapie.

Methoden: Basierend auf einer selektiven Literaturrecherche wurde der aktuelle Wissensstand zur Verwendung von KI in der Strahlentherapie zusammengefasst und kritisch diskutiert.

Ergebnisse: Erste zugelassene Softwarelösungen ermöglichen die automatisierte Konturierung von Risikoorganen im Planungs-CT, die dann bei der Bestrahlungsplanung geschont werden. Die Qualität dieser KI-generierten Risikoorgane ist in den meisten Fällen bereits sehr gut und bedarf oftmals nur geringer Anpassungen. Auch die von KI-Anwendungen erstellten lokoregionären Lymphabflusswege als Teil des therapeutischen Zielgebiets sind mittlerweile in vielen Fällen vergleichbar mit den von Experten erstellten Konturen. Insbesondere bei der adaptiven Strahlentherapie sind KI-basierte Anwendungen ein essenzieller Bestandteil, um in kurzer Zeit den Bestrahlungsplan an die tagesaktuelle Patienten-anatomie anzupassen. KI-basierte Prognose- und Prädiktionsstools konnten ebenfalls vielversprechende Ergebnisse erzielen; allerdings steht hier noch die prospektive Validierung an großen multizentrischen Kollektiven in vielen Fällen aus, bevor eine Anwendung in der klinischen Routine erfolgen kann.

Schlussfolgerungen: Die Integration von KI in die Strahlentherapie ist in den letzten Jahren deutlich vorangeschritten und wird bereits bei einigen Arbeitsschritten in der klinischen Routine eingesetzt. KI-basierte Anwendungen können die strahlentherapeutische Arbeit erheblich beschleunigen und somit den Personalaufwand verringern. Zudem können sie bei der Konturierung der Tumoren und Risikoorganen zu einer höheren Standardisierung führen und bei richtigem Einsatz die Qualität erhöhen.

Schlüsselwörter

Maschinelles Lernen · „Deep learning“ · Radiochemotherapie · Bildgebung · Computertomographie

Die Strahlentherapie stellt neben der Chirurgie und Systemtherapie eine der drei wesentlichen Säulen der Krebstherapie dar, was bereits durch die Tatsache unterstrichen wird, dass etwa 50% aller Krebspatienten in Europa eine Strahlentherapie erhalten [9]. Dabei wird die Strahlentherapie sowohl mit kurativer als auch mit palliativer Intention eingesetzt, Letzteres beispielsweise zur Reduktion von Schmer-

zen bei Knochenmetastasen oder zur Beendigung von Tumorblutungen.

Die strahlentherapeutische Behandlungskette umfasst die Indikationsstellung im Rahmen des strahlentherapeutischen Aufklärungsgesprächs, die Erstellung des Zielvolumens üblicherweise auf Basis eines Planungscomputertomogramms unter Berücksichtigung der diagnostischen Bildgebungen, die physikalische Bestrah-




Abb. 1 ▲ Planungscomputertomographie eines Schädels mit automatisch erstellten Konturen für den Hirnstamm, die Augenlinsen, die Tränendrüsen sowie das Auge. Die Risikoorgane wurden mit verschiedenen Autokonturierungssoftwareprodukten im Jahr 2022 konturiert (Limbus Contour von Limbus AI, Automatic Segmentation Service von MVision, Annotate von Therapanacea, ProSoma von MedCom sowie ein atlasbasiertes und zwei Deep-Learning-basierte Tools von Raysearch)

lungsplanung inklusive Dosisverifikation, die eigentliche Bestrahlung am Linearbe-

schleuniger mit Verifikation der richtigen Patientenlagerung sowie die strahlentherapeutische Nachsorge mit regelmäßigen Kontrollen des Behandlungserfolgs und dem Management von Nebenwirkungen. In den letzten Jahren hat der Einsatz von künstlicher Intelligenz (KI) in all diesen Schritten der strahlentherapeutischen Behandlungskette rasant an Bedeutung gewonnen. Exemplarisch werden im Folgenden KI-basierte Anwendungen in den Bereichen der (Planungs-)Computertomographie, der adaptiven Strahlentherapie, der Autokonturierung von Risikoorganen und Zielvolumina sowie der Prognose- und Prädiktionsmodelle vorgestellt.

Bildgebung und adaptive Strahlentherapie

Eine Situation, bei der KI-basierte Vorhersagemodelle eine große klinische Konsequenz hätten, wäre die Vorhersage eines möglichen histopathologischen Lymphknotenkapselfurchs (ECE) bei Patienten mit Kopf-Hals-Tumoren. Der Hintergrund ist, dass diese Patienten mit

Nachweis eines ECE im Anschluss an die Tumoroperation i. d. R. eine postoperative Strahlenchemotherapie anstelle einer alleinigen Strahlentherapie benötigen [1]. Insbesondere bei Patienten mit HPV-positiven Oropharynxkarzinomen, bei denen aufgrund der oftmals sehr guten Prognose eine Deeskalation im Rahmen von Studien untersucht wird, konnten vergangene Analysen jedoch eine signifikant erhöhte Toxizität bei trimodalen Therapien (d. h. Operation plus postoperative Strahlenchemotherapie) zeigen [15]. Daher hätte insbesondere bei Patienten mit Oropharynxkarzinom im Tumorstadium I–II (8. TNM-UICC-Klassifikation), bei denen die definitive Strahlenchemotherapie onkologisch gleichwertig zur Operation mit postoperativer Strahlen(chemo)therapie ist [12], die radiologische Vorhersage eines histopathologischen ECE für die Diskussion innerhalb des Tumorboards und mit den Patienten eine große Konsequenz. Hier wurden in den vergangenen Jahren tatsächlich große Fortschritte erzielt. So konnten Kann et al. [6] in einer Post-hoc-Analyse der randomisierten E3311-Studie

Hier steht eine Anzeige.




Abb. 2 ▲ Risikoorgane und Lymphabflusswege im Kopf-Hals-Bereich mithilfe einer kommerziell verfügbaren Autokonturierungssoftware. Die Risikoorgane und Lymphabflusswege wurden mithilfe von Limbus Contour (Limbus AI Inc., Regina, SK, Canada) erstellt. *Hellgrün*: Submandibulardrüsen, *gelb*: Rückenmark, *orange*: Plexus brachialis, *rot*: oberer Konstriktormuskel, *dunkelgrün*: Mandibula, *blau (links) bzw. blassrosa (rechts)*: Lymphabflusswege (Level Ib, II und VIIa [retropharyngeal])

mit 178 analysierten Lymphknoten zeigen, dass ihr entwickelter Deep-Learning-basierter Algorithmus eine signifikant bessere Vorhersage des ECE-Status erzielte als die von 4 erfahrenen Radiologen. Jedoch sind noch weitere prospektive multizentrische Studien notwendig, bei denen die Performance dieses Deep-Learning-Algorithmus in Situationen mit heterogenen CT-Untersuchungsparametern untersucht wird.

Große Fortschritte wurden in den letzten Jahren dabei erzielt, die Bildqualität von Cone Beam-Computertomographie (CBCT)-Aufnahmen, die v.a. zur optimalen Patientenpositionierung auf dem Bestrahlungstisch dienen, zu verbessern und diese im Rahmen der adaptiven Strahlentherapie als Grundlage für die Dosisberechnung zu verwenden [7]. Die adaptive Strahlentherapie ermöglicht es, die Behandlung an die täglichen anatomischen Veränderungen des Patienten (z. B. unterschiedliche Blasenfüllung bei einer Strahlentherapie im Beckenbereich) anzupassen und somit die Strahlenbehandlung präziser zu gestalten. Bei der Onlineadaptation werden, noch während der Patient auf dem Behandlungstisch liegt, die Risikoorgane und Zielvolumina auf Basis der tagesaktuellen CBCT-Aufnahme (oder bei

einem MR-basierten Linearbeschleuniger auf Basis einer Magnetresonanztomographie) neu erstellt und ein optimierter Bestrahlungsplan wird berechnet. Eine KI-Unterstützung bietet hier die Möglichkeit, diesen Prozess deutlich schneller durchzuführen, beispielsweise etwa 30 min bei einer adaptiven Strahlentherapie im Kopf-Hals-Bereich [3].

Konturierung von Risikoorganen

Die Konturierung von Risikoorganen ist eine elementare Voraussetzung für die Berücksichtigung dieser Normalgewebestrukturen bei der Bestrahlungsplanung mit dem ultimativen Ziel, die Dosis dieser Strukturen unter bestimmten Grenzwerten zu halten. Der zeitliche Aufwand der Konturierung ist erheblich, insbesondere in bestimmten Lokalisationen wie im Cerebrum oder im Kopf-Hals-Bereich. Zunehmend finden daher kommerzielle Softwareprodukte Anwendung, die basierend auf KI die Konturierung der Risikoorgane übernehmen (■ **Abb. 1**). Hier werden i. d. R. Deep-Learning-Algorithmen wie dreidimensionale Convolutional Neural Networks (CNN) eingesetzt, insbesondere Varianten des 3D-U-Net. Diese Algorithmen wurden auf großen und heterogenen Datensätzen trainiert, bei denen zuvor eine manuelle Konturierung der Risikoorgane durchgeführt worden war, und anschließend an repräsentativen Testkohorten validiert. Die Übereinstimmung der so erstellten Normalgewebestrukturen mit den ärztlich konturierten Strukturen ist sehr hoch: Studien berichteten über Dice-Similarity-Koeffizienten, die ein Maß für die Übereinstimmung der Strukturen darstellen (maximal möglicher Wert ist 1 und höhere Werte bedeuten eine höhere Übereinstimmung), von > 0,8 für die am häufigsten verwendeten Risikoorgane [17, 18]. Zudem wurde eine deutliche Zeitersparnis durch die Verwendung dieser KI-basierten Softwareprodukte beobachtet. Eine Vergleichsstudie von 5 unterschiedlichen Programmen zeigte beispielsweise eine Zeitersparnis von etwa einer Viertelstunde pro Fall bei der Konturierung von Risikoorganen für Mammakarzinomfälle und 1,5 h für Kopf-Hals-Tumor-Fälle [2]. Insbesondere bei kleinen Strukturen wie dem Chiasma opticum oder dem Hippo-

campus weisen die Deep-Learning-basierten Methoden jedoch noch Schwächen auf und bedürfen weiterer Optimierungen [17].

Ein Beispiel für die mögliche klinische Relevanz von KI-basierter Autokonturierung der Risikoorgane ist eine Post-hoc-Analyse von Thor et al. [16] zur randomisierten RTOG-0617-Studie, die keine Verbesserung des Gesamtüberlebens bei einer höheren Strahlendosis (74 Gy) im Vergleich zur Standarddosis (60 Gy) bei der Strahlenchemotherapie des nicht-kleinzelligen Bronchialkarzinoms zeigen konnte. Die Anwendung einer Deep-Learning-basierten Autosegmentierung verbesserte die Konsistenz und Genauigkeit der Segmentierung von kardialen Substrukturen. Die Dosisexposition dieser Deep-Learning-basierten kardialen Substrukturen war zudem stärker mit dem Gesamtüberleben assoziiert als die manuell konturierten Substrukturen. Somit haben KI-basierte Autosegmentierungen von Normalgewebestrukturen das Potenzial, die Standardisierung und Qualität in diesem Bereich zu erhöhen.

Konturierung des Zielvolumens

In der Strahlentherapie beschreibt das „gross tumor volume“ (GTV) das makroskopisch sichtbare Tumolvolumen, das mittels bildgebender Verfahren und klinischer Untersuchung identifiziert wird. Das „clinical target volume“ (CTV) schließt das GTV sowie zusätzlich möglicherweise mikroskopisch befallene Regionen ein. Das „planning target volume“ (PTV) erweitert schließlich das CTV um einen Sicherheitsabstand, um Bewegungen des Patienten und Unsicherheiten in der Patientenpositionierung und Strahlentherapieplanung auszugleichen.

Die KI-basierte Konturierung des GTV ist bisher weitgehend noch Gegenstand von Studien und nicht in der täglichen Routine angekommen. Bisherige Studienergebnisse hierzu sind jedoch vielversprechend und könnten zur Reduktion der Interobserver-Variabilität der GTV-Konturierung beitragen [5, 13]. In einer Studie von Hosny et al. [5] wurden beispielsweise bei Lungenkrebspatienten 3D-U-Net-Modelle mit anschließender nnU-Net-Optimierung eingesetzt, um den Primärtumor und die

befallenen Lymphknoten zu segmentieren. Obwohl die Modelle im Vergleich zur Interobserver-Benchmark eine sehr gute Performance zeigten, übertrafen sie den Benchmark nicht, wenn sie basierend auf externen Daten (segmentiert von verschiedenen Experten) bewertet wurden. Die KI-Unterstützung reduzierte allerdings die Segmentierungszeit um 65 % (auf 5,4 min) und die Interobserver-Variabilität um 32 %.

Etwas anders verhält es sich mit den Lymphabflussgebieten, die dem CTV zuzuordnen sind. Hier haben die meisten kommerziell verfügbaren KI-basierten Softwares mittlerweile automatisch erstellte Lymphabflussregionen in ihren Leistungsumfang integriert (■ Abb. 2). In einer kürzlich veröffentlichten Studie auf Basis von 30 Patienten mit Prostatakarzinom zeigte sich beispielsweise, dass die untersuchte Deep-Learning-basierte Software die Zeit zur Erstellung klinisch akzeptabler Konturen sowohl der Risikoorgane als auch der Prostata und der Lymphabflusswege um 26 min reduzierte. Für alle KI-basiert erstellten Konturen wurden Dice-Similarity-Koeffizienten von über 0,7 berechnet [14].

Schwierigkeiten in der CTV-Erstellung bestehen grundsätzlich insbesondere noch für Patienten mit anatomischen Besonderheiten und nach stattgefundenen Operationen [11]. Bei einigen Tumorentitäten besteht zudem die Herausforderung zu entscheiden, auf welcher Konsensarbeit die Konturierung der Lymphabflussregion basieren soll; beispielsweise existieren gewisse Unterschiede in Bezug auf die anatomischen Grenzen bei den lokoregionären Lymphabflusswegen des Mammakarzinoms zwischen der Empfehlung der Radiation Therapy Oncology Group und der der European Society for Radiotherapy and Oncology [10].

Prognose- und Prädiktionsmodelle

Ein weiteres klinisch relevantes Beispiel, bei dem KI-basierte Vorhersagemodelle nützlich für die strahlentherapeutische Behandlung sein könnten, ist die Prädiktion eines Komplettansprechens nach neoadjuvanter Strahlenchemotherapie des Rektumkarzinoms. Eine relativ aktuelle Post-hoc-Analyse von Li et al. [8] auf Basis einer randomisierten multizentrischen Studie konnte einen U-Net-basierten Algorith-

Artificial intelligence in radiotherapy

Background: Radiotherapy is a cornerstone of cancer treatment, and approximately half of all cancer patients receive radiotherapy during their course of disease. Artificial intelligence (AI) can be employed at all stages of this process to enhance precision, efficiency, and personalization.

Objective: This study represents a critical assessment of the current use of AI in radiotherapy.

Methods: Based on a selective literature review, the current state of knowledge regarding AI in radiotherapy was summarized and critically discussed.

Results: First approved software solutions enable automated contouring of organs at risk which is crucial for radiation treatment planning. The quality of AI-generated contours for these organs is generally high and typically requires minimal human adjustment. AI applications also produce contours of locoregional lymphatic drainage pathways as part of the therapeutic target volume which are comparable to those created by experts in many cases. Especially in adaptive radiotherapy, AI-based applications are essential for swiftly adjusting treatment plans to accommodate daily changes in patient anatomy. AI-based prognosis and prediction tools have also shown promising results, but in most cases, prospective validation in large multicenter cohorts is still pending before these can be used in clinical routine.

Conclusions: The integration of AI into radiotherapy has advanced significantly in recent years and is already being clinically applied in several domains. AI-based applications have the potential to significantly accelerate radiotherapy processes, thereby reducing personnel workload. Moreover, they can contribute to standardizing tumor and organ at risk contouring, potentially enhancing quality when used correctly.

Keywords

Machine learning · Deep learning · Radiochemotherapy · Imaging · Computed tomography

mus entwickeln, der sowohl den Primärtumor konturieren (Dice-Similarity-Koeffizient von 0,79) als auch ein Komplettansprechen auf die neoadjuvante Behandlung (Chemotherapie oder Strahlentherapie) mit einer Sensitivität von 0,812 und einer Spezifität von 0,725 vorhersagen konnte. Hier sind allerdings noch weitere Validierungsstudien notwendig, bevor solche KI-basierten Prädiktionsmodelle in die klinische Routine integriert und somit bei den Patienten berücksichtigt werden könnten.

Prätherapeutische Sarkopenie hat einen signifikanten Einfluss auf die Inzidenz radiogener Toxizitäten sowie die Gesamtprognose bei Patienten mit Kopf-Hals-Tumoren [4]. Die manuelle Segmentierung der Skelettmuskulatur ist allerdings sehr zeitaufwendig und unterliegt einer gewissen Interobserver-Variabilität, sodass Deep-Learning-basierte Anwendungen hier eine Möglichkeit wären, diese wichtige Information schnell und reliabel den Behandlern zur Verfügung zu stellen. Eine kürzlich veröffentlichte Studie von der Harvard Medical School

zeigte das Potenzial einer solchen KI-basierten Lösung [19]: An einer Kohorte von 899 Patienten mit Kopf-Hals-Tumoren, die eine primäre Strahlentherapie erhielten, wurde eine vollautomatisierte Deep-Learning-Plattform zur Segmentierung der Nackenmuskulatur entwickelt und extern validiert; der Dice-Similarity-Koeffizient bezogen auf die Expertenkonturen betrug 0,9. Der KI-basiert berechnete Skelettmuskulaturindex war signifikant mit dem Überleben und einer längerfristigen Ernährungsabhängigkeit von der perkutanen endoskopischen Gastrostomie(PEG)-Sonde assoziiert. Die Integration solcher Anwendungen könnte mittelfristig eine zunehmend personalisierte Strahlentherapie ermöglichen, bei der beispielsweise die Dosis auf die Schluckmuskulatur abhängig von der zu erwartenden Wahrscheinlichkeit einer dauerhaften PEG-Sonden-Abhängigkeit angepasst werden könnte.

Fazit für die Praxis

- Die adaptive Strahlentherapie profitiert enorm von der Integration KI-basierter Anwendungen in die klinische Routine, insbesondere bei der Verbesserung der CBCT-Bildqualität, der Autokonturierung der Risikoorgane und der Erstellung eines modifizierten Bestrahlungsplans – alles innerhalb der Zeit, während der Patient auf dem Bestrahlungstisch liegt.
- Die in der klinischen Routine eingesetzten KI-Anwendungen zur Autokonturierung von Risikoorganen erzielen regelhaft eine hohe Qualität, sodass diese Strukturen oftmals ohne große Änderungen übernommen werden.
- Die KI-gestützte Konturierung der Lymphabflusswege ist in vielen Fällen von guter Qualität, allerdings bedarf die KI-basierte Konturierung des makroskopischen Tumors selbst weiterer Studien.
- KI-basierte Prognose- und Prädiktionsmodelle können zukünftig zur Personalisierung der Strahlentherapie beitragen, allerdings sind hier noch prospektive multizentrische Studien notwendig, um die bisher entwickelten Modelle zu validieren.

Korrespondenzadresse

PD Dr. med. Alexander Rühle, MHBA
 Klinik und Poliklinik für Strahlentherapie,
 Universitätsklinikum Leipzig
 Stephanstr. 9a, 04103 Leipzig, Deutschland
 alexander.ruehle@medizin.uni-leipzig.de

Danksagung. Der Autor bedankt sich bei Herrn Felix Christian Kegler für die Erstellung der **Abb. 1**, die im Rahmen seiner Masterarbeit entstanden ist.

Einhaltung ethischer Richtlinien

Interessenkonflikt. A. Rühle erhielt Referenten- und Beraterhonorare, Reisekostenunterstützung sowie Forschungsgelder von Novocure, sowie ein Referentenhonorar von Merck Healthcare Germany.

Für diesen Beitrag wurden von den Autor/-innen keine Studien an Menschen oder Tieren durchgeführt. Für die aufgeführten Studien gelten die jeweils dort angegebenen ethischen Richtlinien.

Literatur

1. Bernier J, Cooper JS, Pajak TF et al (2005) Defining risk levels in locally advanced head and neck cancers: a comparative analysis of concurrent postoperative radiation plus chemotherapy trials of the EORTC (#22931) and RTOG (# 9501). *Head Neck* 27:843–850
2. Doolan PJ, Charalambous S, Roussakis Y et al (2023) A clinical evaluation of the performance of five commercial artificial intelligence contouring systems for radiotherapy. *Front Oncol* 13:1213068
3. Guberina M, Guberina N, Hoffmann C et al (2024) Prospects for online adaptive radiation therapy (ART) for head and neck cancer. *Radiat Oncol* 19:4
4. Haehl E, Alvino L, Rühle A et al (2022) Sarcopenia as a Prognostic Marker in Elderly Head and Neck Squamous Cell Carcinoma Patients Undergoing (Chemo-)Radiation. *Cancers* 14:
5. Hosny A, Bitterman DS, Guthier CV et al (2022) Clinical validation of deep learning algorithms for radiotherapy targeting of non-small-cell lung cancer: an observational study. *Lancet Digit Health* 4:e657–e666
6. Kann BH, Likitlersuang J, Bontempi D et al (2023) Screening for extranodal extension in HPV-associated oropharyngeal carcinoma: evaluation of a CT-based deep learning algorithm in patient data from a multicentre, randomised de-escalation trial. *Lancet Digit Health* 5:e360–e369
7. Kida S, Kaji S, Nawa K et al (2020) Visual enhancement of cone-beam CT by use of CycleGAN. *Med Phys* 47:998–1010
8. Li L, Xu B, Zhuang Z et al (2023) Accurate tumor segmentation and treatment outcome prediction with DeepTOP. *Radiother Oncol* 183:109550
9. Lievens Y, Borrás JM, Grau C (2020) Provision and use of radiotherapy in Europe. *Mol Oncol* 14:1461–1469
10. Loganadane G, Truong PT, Taghian AG et al (2020) Comparison of Nodal Target Volume Definition in Breast Cancer Radiation Therapy According to RTOG Versus ESTRO Atlases: A Practical Review From the TransAtlantic Radiation Oncology Network (TRONE). *Int J Radiat Oncol Biol Phys* 107:437–448
11. Matoska T, Patel M, Liu H, Beriwal S (2024) Review of Deep Learning Based Autosegmentation for Clinical Target Volume: Current Status and Future Directions. *Adv Radiat Oncol* 9:101470
12. Nichols AC, Theurer J, Prisman E et al (2022) Randomized trial of radiotherapy versus transoral robotic surgery for oropharyngeal squamous cell carcinoma: long-term results of the ORATOR trial. *J Clin Oncol* 40:866–875
13. Peeken JC, Etzel L, Tomov T et al (2024) Development and benchmarking of a Deep Learning-based MRI-guided gross tumor segmentation algorithm for Radiomics analyses in extremity soft tissue sarcomas. *Radiother Oncol* 197:110338
14. Starke A, Poxon J, Patel K et al (2024) Clinical evaluation of the efficacy of limbus artificial intelligence software to augment contouring for prostate and nodes radiotherapy. *Br J Radiol* 97:1125–1131
15. Taylor KJ, Amdal CD, Bjordal K et al (2024) Long-term health-related quality of life in head and neck cancer survivors: A large multinational study. *Int J Cancer* 154:1772–1785
16. Thor M, Apte A, Haq R et al (2021) Using Auto-Segmentation to Reduce Contouring and Dose Inconsistency in Clinical Trials: The Simulated Impact on RTOG 0617. *Int J Radiat Oncol Biol Phys* 109:1619–1626
17. Turcas A, Leucuta D, Balan C et al (2023) Deep-learning magnetic resonance imaging-based automatic segmentation for organs-at-risk in the brain: Accuracy and impact on dose distribution. *Phys Imaging Radiat Oncol* 27:100454
18. Van Dijk LV, Van Den Bosch L, Aljabar P et al (2020) Improving automatic delineation for head and neck organs at risk by Deep Learning Contouring. *Radiother Oncol* 142:115–123
19. Ye Z, Saraf A, Ravipati Y et al (2023) Development and Validation of an Automated Image-Based Deep Learning Platform for Sarcopenia Assessment in Head and Neck Cancer. *Jama Netw Open* 6:e2328280–e2328280

Hinweis des Verlags. Der Verlag bleibt in Hinblick auf geografische Zuordnungen und Gebietsbezeichnungen in veröffentlichten Karten und Institutsadressen neutral.