

Onkologie 2023 · 29:182–191  
<https://doi.org/10.1007/s00761-022-01282-w>  
 Angenommen: 14. Dezember 2022  
 Online publiziert: 23. Januar 2023  
 © The Author(s), under exclusive licence to  
 Springer Medizin Verlag GmbH, ein Teil von  
 Springer Nature 2023



# Bildgebende Diagnostik und der Einsatz von künstlicher Intelligenz beim Management von Organmetastasen

Nithya Bhasker<sup>1</sup> · Felix Schön<sup>2</sup> · Jens Peter Kühn<sup>2</sup> · Stefanie Speidel<sup>1</sup>

<sup>1</sup> Translationale Chirurgische Onkologie, Nationales Centrum für Tumorerkrankungen (NCT/UCC) Dresden, Dresden, Deutschland

<sup>2</sup> Institut und Poliklinik für Diagnostische und Interventionelle Radiologie, Medizinische Fakultät Carl Gustav Carus an der TU Dresden, Dresden, Deutschland

## Zusammenfassung

Die diagnostische Bildgebung spielt eine Schlüsselrolle bei der Erkennung des Primärtumors und möglicher Metastasen. Nach den aktuellen Leitlinien wird zu diesem Zweck die kontrastverstärkte Computertomographie (CT) eingesetzt sowie die Magnetresonanztomographie (MRT) als ergänzende Methode zur Beurteilung von Strukturen wie z. B. des Gehirns. Insbesondere die Differenzierung von Differenzialdiagnosen ist eine tägliche Herausforderung für die Radiologie. Der Einsatz von künstlicher Intelligenz (KI) zur Optimierung von Arbeitsabläufen, zur Unterstützung der Bildbefundung und zur Beurteilung des Therapieergebnisses im Hinblick auf die therapeutische Relevanz ist dringend erforderlich. Radiomics bezeichnet die computergestützte Extraktion und Analyse einer großen Anzahl von Merkmalen aus radiologischen Bildern mithilfe von KI. Zahlreiche Studien haben gezeigt, dass Radiomics die Entdeckung von bildgebenden Biomarkern für die Vorhersage von Behandlungsergebnissen bei Krebspatienten erleichtert. In diesem Zusammenhang ist eine interdisziplinäre Zusammenarbeit unerlässlich.

### Schlüsselwörter

Radiologie · Radiomics · Risikovorhersage für Metastasen · Differenzialdiagnosen · Computergestützte Diagnosen

## In diesem Beitrag

- **Metastasierungsmuster**
- **Diagnostik zur Detektion von Metastasen**  
Lungenmetastasen • Lebermetastasen
- **Potenzial der künstlichen Intelligenz**  
Scannereffekte • Segmentierung von Tumoren • Lernen repräsentativer Merkmale • Vorhersage des Outcomes • Herausforderungen für die Anwendung

**Bildgebende Diagnostik ist entscheidend in der Detektion des Primärtumors und potenzieller Metastasen. Nach den gängigen Leitlinien wird hierfür eine kontrastmittelgestützte Computertomographie (CT) sowie die Magnetresonanztomographie (MRT) als komplementäres Verfahren zur Beurteilung von Strukturen wie beispielsweise Hirnstrukturen durchgeführt. Vor allem die Abgrenzung von Differenzialdiagnosen stellt für die Radiologie eine tägliche Herausforderung dar.**

Der Einsatz von künstlicher Intelligenz (KI) zur Optimierung der Arbeitsabläufe, für die Unterstützung der Bildbefundung und zur Beurteilung des Therapieoutcomes im Sin-

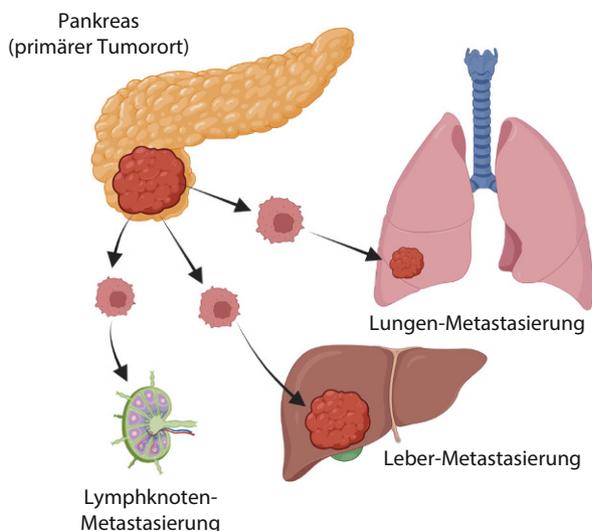
ne der therapeutischen Relevanz wird dringend benötigt. Radiomics bezeichnet die computergestützte Extraktion und Analyse einer großen Anzahl von Merkmalen aus radiologischen Bildern mithilfe von KI. Zahlreiche Studien haben gezeigt, dass Radiomics die Entdeckung bildgebender Biomarker für die Vorhersage des Outcomes bei Krebspatienten erleichtert. Eine interdisziplinäre Zusammenarbeit ist in diesem Kontext unerlässlich.

## Metastasierungsmuster

Das Vorliegen einer Metastasierung eines Malignoms deutet prinzipiell auf ein fortgeschrittenes Tumorstadium und somit auch auf eine schlechte Prognose



QR-Code scannen & Beitrag online lesen



**Abb. 1** ◀ Typische Metastasierungswege des Pankreaskarzinoms mit Tumorausdehnung lymphogen in angrenzende Lymphknoten sowie hämatogen typischerweise in Leber und Lunge. Abbildung erstellt mit BioRender.com

hin. Nach dem statistischen Bundesamt sind Krebserkrankungen die zweithäufigste Todesursache und nahezu für jeden 4. Todesfall verantwortlich (<https://www.destatis.de/>).

### » Die hohe Mortalität von Tumoren ist in bis zu 90% der Fälle durch Metastasen verursacht

Hierbei ist die hohe Mortalität in bis zu 90% der Fälle durch Metastasen verursacht. In Abhängigkeit von der Diagnosestellung des Primärtumors und dem Auftreten einer Metastasierung wird die synchrone von einer metachronen Metastasierung unterschieden. Bei der synchronen Metastasierung wird die Metastase mit dem Primärtumor oder innerhalb von 90 Tagen nach initialer Tumordiagnose detektiert. In diesen Fällen erfolgt die Diagnose des Primärtumors häufig über die histopathologische Sicherung einer vorhandenen Metastase. Bei einer metachronen Metastasierung treten Metastasen erst im zeitlichen Intervall nach Primärtumordiagnostik auf.

In Abhängigkeit von der Art und Lokalisation zeigen Malignome ein unterschiedliches Metastasierungsverhalten (▣ **Abb. 1**). Prinzipiell kann ein bösartiger Tumor in alle Organe metastasieren. Dennoch folgen die meisten Malignome einem typischen Metastasierungsmuster. Die Kenntnis der Metastasierungswege ist für die Primärtumordiagnostik und den darauffolgenden Staginguntersuchungen

von entscheidender Bedeutung. Während die hämatogene Ausbreitung von Metastasen die Organe betreffen, sind bei einer Verbreitung über die Lymphbahnen vorwiegend die dem Primärtumor nahegelegenen Lymphknoten betroffen. Die typischen Metastasierungswege am Beispiel typischer abdomineller Tumoren sind im ▣ **Tab. 1** aufgeführt. Eine Metastase besitzt hinsichtlich ihrer Bildmorphologie ein ähnliches Muster wie der zugrunde liegende Primärtumor [56]. So unterscheiden sich beispielsweise Lungenmetastasen von Primärtumoren der Lunge und ähneln dem Primärtumor des Organs, von dem die Metastase ausgeht.

### Diagnostik zur Detektion von Metastasen

Der bildgebenden Diagnostik kommt eine Schlüsselposition in der Detektion des Primärtumors und potenzieller Metastasen zu. Für die Einteilung des Tumorstadiums und hier vorrangig zum Ausschluss von Metastasen ist die Durchführung einer Schnittbilddiagnostik essenziell. Nach den gängigen Leitlinien wird hierfür eine kontrastmittelgestützte Computertomographie (CT) als robustes und breit verfügbares Verfahren empfohlen. In einigen Leitlinien, wie z. B. zum malignen Melanom, Lungenkarzinom und hepatozellulären Karzinom, wird die Magnetresonanztomographie (MRT) als komplementäres Verfahren zur Beurtei-

lung der Hirnstrukturen bzw. der Leber durchgeführt.

Die technischen Weiterentwicklungen der Schnittbildverfahren steigerten die diagnostische Genauigkeit der Metastasen-detektion und -charakterisierung. Durch die Einführung neuer CT-Gerätegenerationen, wie der Mehrschicht-CT konnte bei reduzierter Strahlenexposition die Bildqualität entscheidend verbessert werden. Die Vorteile dieser Geräte sind die kürzere Scandauer, ein größeres Scanvolumen und die Anfertigung von Bildern mit niedriger Schichtdicke. Eine aktuelle Weiterentwicklung der Mehrschicht-CT ist die Dual-Energy-CT. Hierbei werden während der Aufnahme Bilder mit 2 energetischen Spektren angefertigt. In der onkologischen Diagnostik besitzt die Dual-Energy-CT Vorteile in einer verbesserten Detektion der Tumoren durch Verwendung von niederenergetischen Bildern sowie der neuen Möglichkeiten zur Tumorcharakterisierung, wie der berechneten nativen Bilder („virtual non contrast“) und der zugehörigen Jodkarten [2].

### » Bei der Dual-Energy-CT werden während der Aufnahme Bilder mit 2 energetischen Spektren angefertigt

Die MRT ist im onkologischen Setting ein alternatives Verfahren, welches vorrangig bei jugendlichen Patienten, bei schwangeren Patientinnen, bei Patienten mit Kontraindikationen der CT und im Screening eingesetzt wird. Die Weiterentwicklungen in der Geräte- und Sequenztechnik erlauben einen verbesserten Einsatz der Geräte in der Tumordiagnostik. Zu erwähnen sind die neuen Möglichkeiten der MRT in der Ganzkörperbildgebung [34], der Einsatz moderner MRT-Sequenztechniken, wie z. B. diffusionsgewichtete Sequenzen [48] und Perfusionsmapping [37], sowie der gezielte Einsatz organspezifischer MRT-Kontrastmittel [15].

Die Hybridbildgebung, wie Positronen-emissionstomographie (PET)-CT und PET-MRT, vereint die funktionelle und anatomische Darstellung des Tumors und deren Absiedlungen. Durch die Einführung spezieller PET-Tracer wird auch zukünftig die Hybridbildgebung einen festen Stellenwert in der onkologischen Bildgebung

**Tab. 1** Organmetastasen – Metastasierungsmuster

Primärtumor	Metastasierung	Häufigkeit (%)
Magenkarzinome [41, 49]	Leber	~40–48
	Peritoneum	32
	Lunge	15
	Knochen	12
Kolorektale Tumoren [52]	Leber	~50
	Lunge	10–15
	Peritoneum	4–13
Leber [14, 16, 22, 50]	Lunge	40–55
	Lymphknoten	41–45
	Knochen	28–40
Pankreas [19, 49, 53]	Leber	30–40
	Lunge	6,8–16,1
	Peritoneum	~14,4

**Tab. 2** Sensitivität der diagnostischen Verfahren in der Detektion von Lebermetastasen

Modalität	Sensitivität
US	69%
CEUS	64,5–91%
CT	CT mit KM 92%
MRT	MRT mit KM: 74% MRT mit spezifischem KM: 87–100% DWI + KM: 96%
PET-CT/-MRT	66%

*CEUS* kontrastmittelverstärkter Ultraschall, *CT* Computertomographie, *DWI* Diffusion weighted imaging, *KM* Kontrastmittel, *MRT* Magnetresonanztomographie, *PET* Positronenemissionstomographie, *US* Ultraschall  
Die MRT mit leberspezifischem Kontrastmittel zeigt die höchste Sensitivität in der Abgrenzung von Lebermetastasen

einnehmen. Im Zuge der Bildgebung für das Lungenkarzinom und das Lymphom ist die PET-CT/-MRT fest in den Leitlinien verankert.

Im Folgenden wird auf die Diagnostik der häufigsten Organmetastasierungsorte der Lunge und der Leber eingegangen.

### Lungenmetastasen

In der Regel treten pulmonale Metastasen multiple und in beiden Lungen verstreut auf. Dabei ist die Morphologie der Metastasen abhängig vom Primärtumor. Im Gegensatz zu den primären pulmonalen Malignomen sind Metastasen meist rundliche scharf begrenzte peripher gelegene Läsionen. Trotz suffizienter Diagnostik stellen gerade kleine, benigne Läsionen als Differenzialdiagnose eine große Herausforderung dar. Im Zuge der Weiterentwicklung der Bildgebung, insbesondere durch die problemlose Akquisition von dünnen Schichten in der CT, können signifikant mehr pulmonale Läsionen detektiert werden [28]. Die CT ist das Verfahren mit der höchsten Sensitivität in der Diagnostik von Lungenmetastasen. Alternative Verfahren, wie die konventionelle Röntgendiagnostik (Sensitivität von 67%) und die MRT (6–9 mm Schichtdicke: 86,4%; < 5 mm Schichtdicke: 43,8%) zeigen eine deutlich niedrigere Sensitivität in der Detektion von Lungenmetastasen ([25]; **Abb. 2**).

### Lebermetastasen

Lebermetastasen imitieren i. d. R. den Primärtumor. Lebermetastasen treten meist multipel verstreut in der Leber auf. Oft ist die Detektion von Lebermetastasen die erste Manifestation einer Tumorerkrankung. Prinzipiell stehen mehrere Verfahren zur Diagnostik von Lebermetastasen zur Verfügung. Eine Übersicht über die Sensitivität in der Detektion von Lebermetastasen ist in der nachfolgenden Tabelle aufgeführt (**Tab. 2**; **Abb. 3**; [30]). Die MRT ist die beste Methode zur Detektion und Charakterisierung von Lebermetastasen [35]. Wie in **Abb. 3** dargestellt, wird das Kontrastmittel von gesunden Leberzellen aufgenommen. Pathologische Leberzellen bleiben ausgespart und werden dadurch visualisiert.

#### » Der Einsatz leberspezifischer Kontrastmittel konnte die MRT-Diagnostik der Leber deutlich verbessern

Insbesondere der Einsatz leberspezifischer Kontrastmittel konnte die MRT-Diagnostik der Leber deutlich verbessern [57].

Durch die Fortschritte in der Geräteentwicklung wird mit den aktuell vorliegenden Verfahren eine hohe Sensitivität und Spezifität in der Detektion von Metastasen erreicht. Hierbei spielen bildmorphologische Charakteristika, wie Form, Grö-

ße, Texturdetails und Multifokalität, eine entscheidende Rolle. Aufgrund der therapeutischen Relevanz von Organmetastasen erfolgt in den meisten Fällen eine histopathologische Sicherung und somit der eindeutige Ausschluss von Differenzialdiagnosen. Die Interpretation von Bildbefunden und die Abgrenzung von Differenzialdiagnosen stellt für die Radiologie eine Herausforderung dar. Der Einsatz von KI zur Optimierung der Arbeitsabläufe, für die Unterstützung der Bildbefundung und zur Beurteilung des Therapieoutcomes könnte hier Abhilfe schaffen.

### Potenzial der künstlichen Intelligenz

Das Potenzial der KI für die bildgestützte Erkennung von Metastasen wird im Folgenden erörtert. Die konventionelle radiologische Befundung basiert auf dem Erkennen tumorspezifischer Bildmerkmale. Dabei setzt die valide Bildinterpretation Erfahrungen des Bildbefunders voraus. Radiomics bezeichnet die computergestützte Extraktion und Analyse einer großen Anzahl quantitativer Merkmale aus radiologischen Bildern. Dabei wird eine Vielzahl von Merkmalen erfasst, welche das Maß der konventionellen Befundung überschreiten.

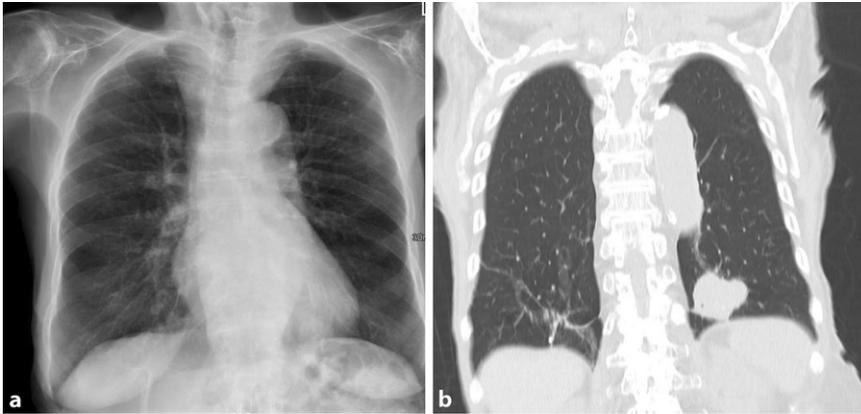
#### » Radiomics erleichtert die Entdeckung bildgebender Biomarker für die Vorhersage des Outcomes

Zahlreiche Studien haben gezeigt, dass Radiomics die Entdeckung bildgebender Biomarker für die Vorhersage des Outcomes bei Krebspatienten erleichtert [1, 24, 26, 38, 39, 51]. Retrospektive Bildanalysen unter Verwendung von KI-Algorithmen und Radiomics-Merkmalen ermöglichen eine frühzeitige Erkennung von Metastasen durch Vorhersage der Zeit, bis der Tumor beginnt, sich von der Primärstelle auszubreiten (progressionsfreies Überleben, PFS). Für eine detaillierte Stratifizierung können die Zeit bis zur Ausbreitung des Tumors in

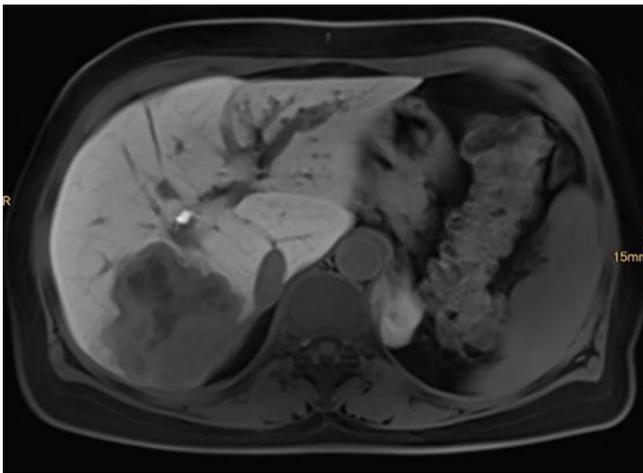
- benachbarte Lymphknoten und Organe – lokoregionäre Rezidive (LRC) – und

Hier steht eine Anzeige.





**Abb. 2** ▲ Validität der konventionellen Röntgendiagnostik im Vergleich zur Computertomographie (CT). Screening nach Lungenmetastasen eines kolorektalen Karzinoms. In der konventionellen Röntgendiagnostik (a) keine pulmonalen Herde abgrenzbar. In der anschließend durchgeführten CT (b) Nachweis einer 4 cm großen Raumforderung im linken Unterlappen, nachfolgend als Metastase histopathologisch gesichert



**Abb. 3** ◀ Lebermetastasen eines kolorektalen Karzinoms in der MRT, angefertigt mit einem leberspezifischen Kontrastmittel in der Spätphase. Erläuterung s. Text

– entfernte Organe – Fernmetastasierung (DM) –

als Surrogatendpunkte verwendet werden [8]. Die KI-gestützte Bildanalyse hilft auch bei der Erkennung und Klassifizierung kleinster Läsionen und Knötchen, die für die Frühdiagnose von Metastasen unerlässlich sind, für Radiologen aber recht mühsam sein können [43].

Ein allgemeiner Radiomics Workflow besteht aus der Datenharmonisierung zum Ausgleich von Unterschieden bei der Bilderfassung, der Segmentierung des Volume of Interest (VOI), der Bildvorverarbeitung, um die Daten vergleichbar zu machen, der Extraktion aussagekräftiger Merkmale, der Dimensionsreduktion oder der Auswahl repräsentativer Merkmale und der Modellanpassung zur Vorhersage

des individualisierten Patientenoutcome (▣ Abb. 4).

Radiomics-Modelle können entweder herkömmliche Bildverarbeitungsmethoden und maschinelle Lernverfahren oder Deep-Learning-Algorithmen für die Vorhersage des Patientenoutcomes verwenden. Im Gegensatz zu traditionellen Methoden, die als Feature-Engineering-Methoden bezeichnet werden, erfordern Deep-Learning-Methoden keine Merkmalsextraktion und -auswahl [5]. In den letzten Jahren hat Deep Learning auch Potenzial für die automatische Segmentierung des VOI gezeigt [21].

### Scannereffekte

In den meisten Fällen sind die aufgenommenen Bilder anfällig für nichtbiologi-

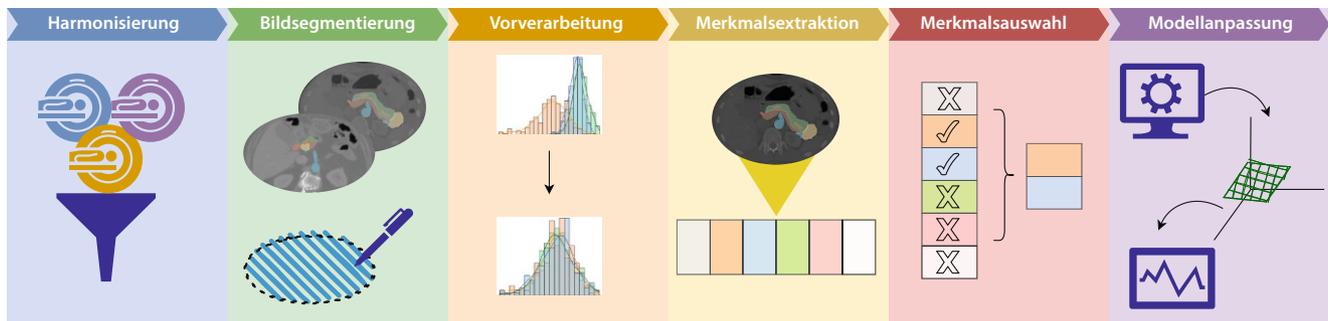
sche Schwankungen aufgrund von Unterschieden bei den Geräteherstellern, der Hardware-/Softwarekonfiguration oder den Aufnahmeprotokollen [13]. In großen multizentrischen Studien beeinträchtigen diese Scannereffekte die anschließende Segmentierung des VOI und die Leistung der Risikoklassifikationsmodelle erheblich [17, 23, 32]. Die unerwünschten Variationen, die sich aus Inkonsistenzen in der Einheit der Intensitätswerte ergeben [54], können durch Methoden zur Intensitätsnormalisierung entfernt werden [36].

### » Scannereffekte sind ungebetene Gäste und können durch Datenharmonisierungstechniken beseitigt werden

Scannereffekte sind ungebetene Gäste und können durch Datenharmonisierungstechniken beseitigt werden, die entweder statistische Methoden verwenden, um ein Mapping zwischen verschiedenen Scannern zu erstellen [54], oder Deep-Learning-Methoden einsetzen, um eine Konsistenz des Kontrasts zwischen den Scans zu erreichen [9]. Bei Feature-Engineering-Ansätzen können Scannereffekte in den extrahierten Merkmalen mithilfe der ComBat-Technik entfernt werden, die ursprünglich im Bereich der Genomik zur Beseitigung von Batch-Effekten eingesetzt wurde [13]. Ein ideales Datenharmonisierungsverfahren würde nur die unerwünschten Artefakte entfernen, ohne die biologischen Variationen zwischen den Scans zu beeinträchtigen.

### Segmentierung von Tumoren

In Radiomics-Modellen, die auf Feature Engineering beruhen, wird eine sinnvolle Merkmalsextraktion durch die VOI begrenzt und erfordert daher eine Segmentierung der anatomischen Strukturen und Pathologien. Die Komplexität der Endpunkte und der Mangel an Beobachtungen erfordern eine Segmentierung des VOI für das Erlernen prognostischer Merkmale in den Deep-Learning-Ansätzen [3]. Methoden zur Vorhersage von Metastasen konzentrieren sich auf die Suche nach Anzeichen von Tumoraggressivität, die sich in Form von Tumorheterogenität



**Abb. 4** ▲ Radiomics Workflow: Harmonisierung der Daten, Bildsegmentierung, Vorverarbeitung, Merkmalsextraktion, Merkmalsauswahl und Modellanpassung

und Malignität der Lymphknoten in Scans manifestieren [1, 4, 51]. Daher kann die Segmentierung des makroskopischen Tumorumfanges und des Lymphknotenbefalls für die Vorhersage von metastasenbezogenen Endpunkten wie dem PFS nützlich sein [4].

Die manuelle Segmentierung von Tumoren kann zeitaufwendig sein und bedarf der Überwachung durch erfahrene Radiologen. Mit dem Aufkommen von U-Net [42], einer beliebten Deep-Learning-Technik für die biomedizinische Bildsegmentierung, wurden in den letzten 10 Jahren mehrere automatische und halbautomatische Segmentierungsverfahren eingeführt [21, 29, 46, 58]. Insbesondere nnU-Net [21], das die Fähigkeit besitzt, die Netzwerkarchitektur für jede gegebene Segmentierungsaufgabe automatisch zu konfigurieren, hat hier einen entscheidenden Beitrag geleistet. Es hat sich nicht nur bei der Segmentierung von anatomischen Strukturen der Organe, sondern auch von pathologischen Läsionen, wie z. B. Tumoren durchgesetzt.

### Lernen repräsentativer Merkmale

Die Vorverarbeitung macht die Bilder verschiedener Patienten vergleichbar und umfasst i. d. R. ein Resampling der Bilder, um Unterschiede in den Voxelabständen, die Begrenzung der Bildintensitäten auf den gewünschten Bereich und die Normalisierung oder Standardisierung der Intensitäten auszugleichen [47]. Je nach Bildgebungsmodalität können zusätzliche Vorverarbeitungsschritte erforderlich sein – z. B. Hintergrund- und Verzerrungsfeldkorrektur bei MRT und Rauschentfernung bei PET-Bildern [45,

51]. Bei Modellen, die auf Deep Learning basieren, ist es üblich, einen zusätzlichen Schritt, die sog. Datenaugmentierung vorzunehmen, um eine bessere Generalisierung zu erreichen. Die Trainingsdaten werden mit translatierten, gedrehten und gespiegelten Versionen der Originaldaten angereichert [3, 20].

Herkömmliche radiologische Merkmale beschreiben den Phänotyp des Tumors quantitativ, indem sie morphologische, statistische, histogrammbasierte und texturbasierte Aspekte des Tumors in Scans extrahieren. Um eine bessere Reproduzierbarkeit zwischen den Studien zu erreichen, werden diese Merkmale in Übereinstimmung mit der Image Biomarker Standardisation Initiative (IBSI) extrahiert, die eine Reihe von Referenzwerten für die Radiomics-Merkmale definiert [59]. Aufgrund der begrenzten Datenverfügbarkeit und der abstrakten metastasenbezogenen Endpunkte ist es üblich, dass Deep-Learning-basierte Radiomics-Modelle einen Multi-Task-Ansatz verfolgen und gleichzeitig mit der Segmentierung Merkmale für die Vorhersage des Outcomes erlernen [3, 12, 33].

### » Von Tumoren zu Merkmalen kommt KI durch Lernen repräsentativer Merkmale aus dem VOI

Von Tumoren zu Merkmalen kommt KI durch Lernen repräsentativer Merkmale aus dem VOI: Da die extrahierten radiologischen Merkmale i. d. R. redundant und hochdimensional sind, werden Techniken zur Dimensionsreduktion wie hierarchisches Clustering und Auswahl von Merkmalen angewandt, um

repräsentative Merkmale für klassische Algorithmen des maschinellen Lernens zu erhalten [27]. Merkmalsauswahlverfahren wie die auf Mutual Information basierende Merkmalsauswahl (MIFS) [6] und die auf minimaler Redundanz und maximaler Relevanz basierende Methode (MRMR) [40] haben eine gute prognostische Leistung für Kopf-Hals-Tumoren erreicht [39]. Bei diesen beiden Methoden handelt es sich um Score-basierte multivariate Merkmalsauswahlverfahren, die eine Merkmalsuntergruppe liefern, die nicht nur für den Endpunkt relevant ist, sondern auch keine Redundanz zu bereits ausgewählten Merkmalen aufweist [39].

### Vorhersage des Outcomes

Frühe Radiomics-Studien konzentrierten sich auf multivariate Analysen mit klassischen maschinellen Lernverfahren. Coroller et al. [7] verwendeten Radiomics-Merkmale, die aus abgegrenzten Primärtumoren in CT-Scans extrahiert wurden, als Input für ein multivariates Cox-Regressionsmodell zur Vorhersage von DM bei Lungenkrebspatienten. Aus ihren Ergebnissen ging hervor, dass Radiomics-Merkmale das Potenzial haben, als prognostische Biomarker für DM verwendet zu werden, und eine Kombination des Radiomics-Modells mit dem klinischen Modell führte zu einer Verbesserung der Ergebnisse.

Da sich die Tumoraggressivität als Heterogenität des Tumorstoffwechsels und der Tumorstruktur manifestieren kann [1, 10, 44], verwendeten Vallières et al. [51] volumenfusionierte PET- und MRT-Scans vor der Behandlung, um die Lungenmetastasierung bei Weichteilsarkomen vorherzusagen. Die Ergebnisse dieser Studie deuten

darauf hin, dass Modelle, die Merkmale aus volumenfusionierten PET- und MRT-Scans verwenden, besser abschneiden als Modelle, die nur Merkmale aus PET-Scans und eine Kombination von Merkmalen aus separaten PET- und MRT-Scans verwenden.

Die Verfügbarkeit großer öffentlicher Datensätze hat den Erfolg von Deep-Learning-Modellen in der medizinischen Bildanalyse vorangetrieben. Heuvelmans et al. [18] beispielsweise nutzten den öffentlichen National Lung Screening Trial (NLST) Datensatz, um ein Deep-Learning-Modell zu trainieren, und erreichten in einem externen Datensatz eine hohe Sensitivität von 99 % für die schwierige Aufgabe der Identifizierung gutartiger Lungenrundherde. Dieser Erfolg zeigte sich jedoch bisher nicht bei der Survival-Analyse, da die Kuration solch großer Datensätze und die Auswahl der Loss-Funktion schwierig ist [20]. Daher wurden in früheren Deep-Learning-basierten Arbeiten Techniken wie Transfer Learning oder Ensemble Learning eingesetzt, um die linearen Basismodelle zu übertreffen [20, 47]. Neuere Deep-Learning-basierte Survival-Analysemethoden verfolgen einen Multitask-Ansatz, bei dem die Merkmalsrepräsentationen in Verbindung mit Segmentierungsmodellen erlernt werden [3].

### » Peritumorale Merkmale erzielten höhere prognostische Leistung als konventionelle Radiomics-Merkmale

Alternative Radiomics-Methoden, die Merkmale aus der extratumoralen Region oder Längsschnittdaten nutzen, haben vielversprechende Ergebnisse für die Vorhersage von Metastasen-Endpunkten gezeigt. Dou et al. [11] untersuchten das Potenzial von Radiomics-Merkmalen für die Vorhersage von DM bei Lungenkrebspatienten, die aus dem äußeren Teil und einer kleinen Randregion des Primärtumors gewonnen wurden. Diese Radiomics-Merkmale wurden als peritumorale Merkmale bezeichnet und erzielten eine höhere prognostische Leistung als konventionelle Radiomics-Merkmale, die allein aus dem Volumen des Primärtumors gewonnen wurden. Xu et al. [55] setzten Deep-Learning-Methoden bei einer Reihe

von Untersuchungen vor und nach der Behandlung ein, um die Veränderungen der Tumoreigenschaften zu verfolgen. Sie erzielten eine gute prognostische Leistung, was das Potenzial von Längsschnittdaten für die Vorhersage von Metastasen zeigt.

### Herausforderungen für die Anwendung

Radiomics hat das Potenzial, die Diagnose und Therapie zu verbessern, allerdings erschweren einige Aspekte die Translation in die klinische Praxis [31]. Die Herausforderungen für die Anwendung von KI in der klinischen Praxis sind zahlreich. Die Aufbereitung von Daten im medizinischen Bereich ist teuer und zeitaufwendig. Die Aufnahme modalität muss sensitiv genug sein, um die durch Metastasen verursachte Heterogenität des Tumorphänotyps zu erfassen. Oft sind die verfügbaren Daten unstrukturiert und stammen nur von einem einzigen Zentrum, was die klinische Evaluation und Anwendung moderner datenintensiver KI-Methoden für die Survival-Analyse erschwert und den Nutzen einschränkt. Da Deep-Learning-Modelle als Black-Box-Modelle gelten, müssen erhebliche Anstrengungen unternommen werden, um die Transparenz und Zuverlässigkeit zu verbessern, beispielsweise durch erklärbare Modelle zur Erläuterung der Entscheidungsgrundlagen. Regulatorische Hürden sowie die fehlende Integration in den klinischen Workflow erschweren weiterhin die Translation.

#### Fazit für die Praxis

- Die Bildinterpretation setzt die Kenntnis typischer Metastasierungswege von Malignomen voraus.
- Die Schnittbildverfahren wie Computertomographie (CT) und Magnetresonanztomographie (MRT) stellen mittlerweile Standardverfahren in der onkologischen Bildgebung dar.
- Radiomics und Deep-Learning-Algorithmen unterstützen und optimieren die Diagnostik.
- Verfahren der künstlichen Intelligenz haben das Potenzial zur Abschätzung des Therapieoutcomes und können in Zukunft für individualisierte Therapiestrategien eingesetzt werden.

#### Korrespondenzadresse

##### Nithya Bhasker

Translationale Chirurgische Onkologie,  
Nationales Centrum für Tumorerkrankungen  
(NCT/UCC) Dresden  
Dresden, Deutschland  
nithya.bhasker@nct-dresden.de

### Einhaltung ethischer Richtlinien

**Interessenkonflikt.** N. Bhasker und S. Speidel arbeiten gemeinsam mit der Fa. Karl Storz im SurgOmics-Projekt (gefördert durch das Bundesministerium für Gesundheit). F. Schön und J.P. Kühn geben an, dass kein Interessenkonflikt besteht.

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. Aerts HJ, Velazquez ER, Leijenaar RT, Parmar C, Grossmann P, Carvalho S, Bussink J, Monshouwer R, Haibe-Kains B, Rietveld D, Hoesbers F, Rietbergen MM, Leemans CR, Dekker A, Quackenbush J, Gillies RJ, Lambin P (2014) Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. *Nat Commun* 5:4006. <https://doi.org/10.1038/ncomms5006>
2. Agrawal MD, Pinho DF, Kulkarni NM, Hahn PF, Guimaraes AR, Sahani DV (2014) Oncologic applications of dual-energy CT in the abdomen. *Radiographics* 34(3):589–612. <https://doi.org/10.1148/rg.343135041>
3. Andrearczyk V, Fontaine P, Oreiller V, Castelli J, Jreige M, Prior JO, Depeursinge A (2021) Multi-task deep segmentation and radiomics for automatic prognosis in head and neck cancer. In: International workshop on Predictive intelligence in Medicine. Springer, Cham, S 147–156
4. Andrearczyk V, Oreiller V, Jreige M, Castelli J, Prior JO, Depeursinge A (2022) Segmentation and classification of head and neck nodal metastases and primary tumors in PET/CT. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, S 4731–4735 <https://doi.org/10.1109/EMBC48229.2022.9871907>
5. Avanzo M, Wei L, Stancanello J, Vallières M, Rao A, Morin O, Mattonen SA, El Naqa I (2020) Machine and deep learning methods for radiomics. *Med Phys* 47(5):e185–e202. <https://doi.org/10.1002/mp.13678>
6. Battiti R (1994) Using mutual information for selecting features in supervised neural net learning. *IEEE Trans Neural Netw* 5(4):537–550. <https://doi.org/10.1109/72.298224>
7. Coroller TP, Grossmann P, Hou Y, Rios Velazquez E, Leijenaar RT, Hermann G, Lambin P, Haibe-Kains B, Mak RH, Aerts HJ (2015) CT-based radiomic signature predicts distant metastasis in lung adenocarcinoma. *Radiother Oncol* 114(3):345–350. <https://doi.org/10.1016/j.radonc.2015.02.015>
8. Delgado A, Guddati AK (2021) Clinical endpoints in oncology—a primer. *Am J Cancer Res* 11(4):1121–1131

Hier steht eine Anzeige.



9. Dewey BE, Zhao C, Reinhold JC, Carass A, Fitzgerald KC, Sotirchos ES, Saidha S, Oh J, Pham DL, Calabresi PA, van Zijl PCM, Prince JL (2019) DeepHarmony: a deep learning approach to contrast harmonization across scanner changes. *Magn Reson Imaging* 64:160–170. <https://doi.org/10.1016/j.mri.2019.05.041>
10. Diehn M, Nardini C, Wang DS, McGovern S, Jayaraman M, Liang Y, Aldape K, Cha S, Kuo MD (2008) Identification of noninvasive imaging surrogates for brain tumor gene-expression modules. *Proc Natl Acad Sci U S A* 105(13):5213–5218. <https://doi.org/10.1073/pnas.0801279105>
11. Dou TH, Coroller TP, van Griethuysen JJM, Mak RH, Aerts HJWL (2018) Peritumoral radiomics features predict distant metastasis in locally advanced NSCLC. *PLoS ONE* 13(11):e206108. <https://doi.org/10.1371/journal.pone.0206108>
12. Fontaine P, Andrearczyk V, Oreiller V, Castelli J, Freije M, Prior JO, Depeursinge A (2021) Fully automatic head and neck cancer prognosis prediction in PET/CT. In: International workshop on multimodal learning for clinical decision support. Springer, Cham, 559–68
13. Fortin JP, Cullen N, Sheline YI, Taylor WD, Aselcioglu I, Cook PA, Adams P, Cooper C, Fava M, McGrath PJ, McInnis M, Phillips ML, Trivedi MH, Weissman MM, Shinohara RT (2018) Harmonization of cortical thickness measurements across scanners and sites. *Neuroimage* 167:104–120. <https://doi.org/10.1016/j.neuroimage.2017.11.024>
14. Fukutomi M, Yokota M, Chuman H, Harada H, Zaitzu Y, Funakoshi A, Wakasugi H, Iguchi H (2001) Increased incidence of bone metastases in hepatocellular carcinoma. *Eur J Gastroenterol Hepatol* 13(9):1083–1088. <https://doi.org/10.1097/00042737-200109000-00015>
15. Granata V, Fusco R, de Lutio di Castelguidone E, Avallone A, Palaia R, Delrio P, Tatangelo F, Botti G, Grassi R, Izzo F, Petrillo A (2019) Diagnostic performance of gadoteric acid-enhanced liver MRI versus multidetector CT in the assessment of colorectal liver metastases compared to hepatic resection. *BMC Gastroenterol* 19(1):129. <https://doi.org/10.1186/s12876-019-1036-7>
16. Habermehl D, Haase K, Rieken S, Debus J, Combs SE (2011) Defining the role of palliative radiotherapy in bone metastasis from primary liver cancer: an analysis of survival and treatment efficacy. *Tumori* 97(5):609–613. <https://doi.org/10.1177/030089161109700512>
17. Hagiwara A, Fujita S, Ohno Y, Aoki S (2020) Variability and standardization of quantitative imaging: monoparametric to multiparametric quantification, radiomics, and artificial intelligence. *Invest Radiol* 55(9):601–616. <https://doi.org/10.1097/RLI.0000000000000666>
18. Heuvelmans MA, Ooijen PMA van, Ather S, Silva CF, Han D, Heussel CP, Hickey W, Kauczor HU, Novotny P, Peschl H, Rook M, Rubtsov R, Stackelberg O von, Tsakok MT, Arteta C, Declercq J, Kadir T, Pickup L, Gleeson F, Oudkerk M (2021) Lung cancer prediction by Deep Learning to identify benign lung nodules. *Lung cancer (Amsterdam, Netherlands)* 154:1–4. <https://doi.org/10.1016/j.lungcan.2021.01.027>
19. Homma Y, Endo I, Matsuyama R, Sho M, Mizuno S, Seyama Y, Hirano S, Aono T, Kitami C, Morita Y, Takeda Y, Yoshida K, Tani M, Kaiho T, Yamamoto Y, Aoki H, Ogawa M, Niguma T, Mataka Y, Kawasaki H, Yamamoto M (2022) Outcomes of lung metastasis from pancreatic cancer: A nationwide multicenter analysis. *J Hepato Biliary Pancreat* 29(5):552–561. <https://doi.org/10.1002/jhbp.1127>
20. Hosny A, Parmar C, Coroller TP, Grossmann P, Zeleznik R, Kumar A, Bussink J, Gillies RJ, Mak RH, Aerts HJWL (2018) Deep learning for lung cancer prognostication: A retrospective multi-cohort radiomics study. *PLoS Med* 15(11):e1002711. <https://doi.org/10.1371/journal.pmed.1002711>
21. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier-Hein KH (2021) nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat Methods* 18(2):203–211. <https://doi.org/10.1038/s41592-020-01008-z>
22. Katyal S, Oliver JH 3rd, Peterson MS, Ferris JV, Carr BS, Baron RL (2000) Extrahepatic metastases of hepatocellular carcinoma. *Radiology* 216(3):698–703. <https://doi.org/10.1148/radiology.216.3.r00se24698>
23. Keenan KE, Gimbutas Z, Dienstfrey A, Stupic KF (2019) Assessing effects of scanner upgrades for clinical studies. *J Magn Reson Imaging* 50(6):1948–1954. <https://doi.org/10.1002/jmri.26785>
24. Kumar V, Gu Y, Basu S, Berglund A, Eschrich SA, Schabath MB, Forster K, Aerts HJ, Dekker A, Fenstermacher D, Goldhof DB, Hall LO, Lambin P, Balagurunathan Y, Gatenby RA, Gillies RJ (2012) Radiomics: the process and the challenges. *Magn Reson Imaging* 30(9):1234–1248. <https://doi.org/10.1016/j.mri.2012.06.010>
25. Kurihara Y, Matsuoka S, Yamashiro T, Fujikawa A, Matsushita S, Yagihashi K, Nakajima Y (2014) MRI of pulmonary nodules. *Am J Roentgenol* 202(3):W210–W216. <https://doi.org/10.2214/AJR.13.11618>
26. Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout RG, Granton P, Zegers CM, Gillies R, Boellard R, Dekker A, Aerts HJ (2012) Radiomics: extracting more information from medical images using advanced feature analysis. *Eur J Cancer* 48(4):441–446. <https://doi.org/10.1016/j.ejca.2011.11.036>
27. Leger S, Zwanenburg A, Pilz K, Lohaus F, Linge A, Zöphel K, Kotzerke J, Schreiber A, Tinhofer I, Budach V, Sak A, Stuschke M, Balermppas P, Rödel C, Ganswindt U, Belka C, Pigorsch S, Combs SE, Mönnich D, Zips D, Richter C (2017) A comparative study of machine learning methods for time-to-event survival data for radiomics risk modelling. *Sci Rep* 7(1):13206. <https://doi.org/10.1038/s41598-017-13448-3>
28. Li WJ, Chu ZG, Zhang Y, Li Q, Zheng YN, Lv FJ (2019) Effect of slab thickness on the detection of pulmonary nodules by use of CT maximum and minimum intensity projection. *Am J Roentgenol* 213(3):562–567. <https://doi.org/10.2214/AJR.19.21325>
29. Li X, Chen H, Qi X, Dou Q, Fu CW, Heng PA (2018) H-denseUNet: hybrid densely connected unet for liver and tumor segmentation from CT volumes. *IEEE Trans Med Imaging* 37(12):2663–2674. <https://doi.org/10.1109/TMI.2018.2845918>
30. Lincke T, Zech CJ (2017) Liver metastases: detection and staging. *Eur J Radiol* 97:76–82. <https://doi.org/10.1016/j.ejrad.2017.10.016>
31. Liu JA, Yang IY, Tsai EB (2022) Artificial intelligence (AI) for lung nodules, from the AJR special series on AI applications. *AJR Am J Roentgenol* 219(5):703–712. <https://doi.org/10.2214/AJR.22.27487>
32. Maclaren J, Han Z, Vos SB, Fischbein N, Bammer R (2014) Reliability of brain volume measurements: a test-retest dataset. *Sci Data* 1:140037. <https://doi.org/10.1038/sdata.2014.37>
33. Meng M, Gu B, Bi L, Song S, Feng DD, Kim J (2022) DeepMITS: deep multi-task learning for survival prediction in patients with advanced nasopharyngeal carcinoma using pretreatment PET/CT. *IEEE J Biomed Health Inform* 26(9):4497–4507. <https://doi.org/10.1109/JBHI.2022.3181791>
34. Morone M, Bali MA, Tunariu N, Messiou C, Blackledge M, Grazioli L, Koh DM (2017) Whole-body MRI: current applications in oncology. *AJR Am J Roentgenol* 209(6):W336–W349. <https://doi.org/10.2214/AJR.17.17984>
35. Neri E, Bali MA, Ba-Salamah A, Boraschi P, Brancatelli G, Alves FC, Grazioli L, Helmberger T, Lee JM, Manfredi R, Marti-Bonmati L, Matos C, Merkle EM, Op De Beeck B, Schima W, Skehan S, Vilgrain V, Zech C, Bartolozzi C (2016) ESGAR consensus statement on liver MR imaging and clinical use of liver-specific contrast agents. *Eur Radiol* 26(4):921–931. <https://doi.org/10.1007/s00330-015-3900-3>
36. Nyúl LG, Udupa JK, Zhang X (2000) New variants of a method of MRI scale standardization. *IEEE Trans Med Imaging* 19(2):143–150. <https://doi.org/10.1109/42.836373>
37. Pahwa S, Liu H, Chen Y, Dastmalchian S, O'Connor G, Lu Z, Badve C, Yu A, Wright K, Chalian H, Rao S, Fu C, Vallines I, Griswold M, Seiberlich N, Zeng M, Gulani V (2018) Quantitative perfusion imaging of neoplastic liver lesions: a multi-institution study. *Sci Rep* 8(1):4990. <https://doi.org/10.1038/s41598-018-20726-1>
38. Parmar C, Grossmann P, Bussink J, Lambin P, Aerts HJWL (2015) Machine learning methods for quantitative radiomic biomarkers. *Sci Rep* 5:13087. <https://doi.org/10.1038/srep13087>
39. Parmar C, Grossmann P, Rietveld D, Rietbergen MM, Lambin P, Aerts HJ (2015) Radiomic machine-learning classifiers for prognostic biomarkers of head and neck cancer. *Front Oncol* 5:272. <https://doi.org/10.3389/fonc.2015.00272>
40. Peng H, Long F, Ding C (2005) Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans Pattern Anal Mach Intell* 27(8):1226–1238. <https://doi.org/10.1109/TPAMI.2005.159>
41. Riihimäki M, Hemminki A, Sundquist K, Sundquist J, Hemminki K (2016) Metastatic spread in patients with gastric cancer. *Oncotarget* 7(32):52307–52316. <https://doi.org/10.18632/oncotarget.10740>
42. Ronneberger O, Fischer P, Brox T (2015) U-net: Convolutional networks for biomedical image segmentation. In: International conference on medical image computing and computer-assisted intervention. Springer, Cham, 5234–241
43. Scholten ET, Horeweg N, Koning HJ de, Vliegenthart R, Oudkerk M, Mali WP, Jong PA de (2015) Computed tomographic characteristics of interval and post screen carcinomas in lung cancer screening. *European radiology* 25(1):81–88. <https://doi.org/10.1007/s00330-014-3394-4>
44. Segal E, Sirlin CB, Ooi C, Adler AS, Gollub J, Chen X, Chan BK, Matcuk GR, Barry CT, Chang HY, Kuo MD (2007) Decoding global gene expression programs in liver cancer by noninvasive imaging. *Nat Biotechnol* 25(6):675–680. <https://doi.org/10.1038/nbt1306>
45. Shahzadi I, Zwanenburg A, Lattermann A, Linge A, Baldus C, Peecken JC, Combs SE, Diefenhardt M, Rödel C, Kirste S, Grosu AL, Baumann M, Krause M, Troost EGC, Löck S (2022) Analysis of MRI and CT-based radiomics features for personalized treatment in locally advanced rectal cancer and

- external validation of published radiomics models. *Sci Rep* 12(1):10192. <https://doi.org/10.1038/s41598-022-13967-8>
46. Siddique N, Paheding S, Elkin CP, Devabhaktuni V (2021) U-net and its variants for medical image segmentation: a review of theory and applications. *IEEE Access* 9:82031–82057
  47. Starke S, Leger S, Zwanenburg A, Leger K, Lohaus F, Linge A, Schreiber A, Kalinauskaitė G, Tinhofer I, Guberina N, Guberina M, Balermipas P, von der Grün J, Ganswindt U, Belka C, Peecken JC, Combs SE, Boeke S, Zips D, Richter C, Löck S (2020) 2D and 3D convolutional neural networks for outcome modelling of locally advanced head and neck squamous cell carcinoma. *Sci Rep* 10(1):15625. <https://doi.org/10.1038/s41598-020-70542-9>
  48. Taron J, Johannink J, Bitzer M, Nikolaou K, Notohamiprodjo M, Hoffmann R (2018) Added value of diffusion-weighted imaging in hepatic tumors and its impact on patient management. *Cancer Imaging* 18(1):10. <https://doi.org/10.1186/s40644-018-0140-1>
  49. Tsilimigras DI, Brodt P, Clavien PA, Muschel RJ, D'Angelica MI, Endo I, Parks RW, Doyle M, de Santibañes E, Pawlik TM (2021) Liver metastases. *Nat Rev Dis Primers* 7(1):27. <https://doi.org/10.1038/s41572-021-00261-6>
  50. Uka K, Aikata H, Takaki S, Shirakawa H, Jeong SC, Yamashina K, Hiramatsu A, Kodama H, Takahashi S, Chayama K (2007) Clinical features and prognosis of patients with extrahepatic metastases from hepatocellular carcinoma. *WJG* 13(3):414–420. <https://doi.org/10.3748/wjg.v13.i3.414>
  51. Vallières M, Freeman CR, Skamene SR, El Naqa I (2015) A radiomics model from joint FDG-PET and MRI texture features for the prediction of lung metastases in soft-tissue sarcomas of the extremities. *Phys Med Biol* 60(14):5471–5496. <https://doi.org/10.1088/0031-9155/60/14/5471>
  52. Vatandoust S, Price TJ, Karapetis CS (2015) Colorectal cancer: metastases to a single organ. *WJG* 21(41):11767–11776. <https://doi.org/10.3748/wjg.v21.i41.11767>
  53. Wangjam T, Zhang Z, Zhou XC, Lyer L, Faisal F, Soares KC, Fishman E, Hruban RH, Herman JM, Laheru D, Weiss M, Li M, De Jesus-Acosta A, Wolfgang CL, Zheng L (2015) Resected pancreatic ductal adenocarcinomas with recurrence limited in lung have a significantly better prognosis than those with other recurrence patterns. *Oncotarget* 6(34):36903–36910. <https://doi.org/10.18632/oncotarget.5054>
  54. Wrobel J, Martin ML, Bakshi R, Calabresi PA, Elliot M, Roalf D, Gur RC, Gur RE, Henry RG, Nair G, Oh J, Papinutto N, Pelletier D, Reich DS, Rooney WD, Satterthwaite TD, Stern W, Prabhakaran K, Sicotte NL, Shinohara RT, NAIMS Cooperative (2020) Intensity warping for multisite MRI harmonization. *Neuroimage* 223:117242. <https://doi.org/10.1016/j.neuroimage.2020.117242>
  55. Xu Y, Hosny A, Zeleznik R, Parmar C, Coroller T, Franco I, Mak RH, Aerts HJWL (2019) Deep learning predicts lung cancer treatment response from serial medical imaging. *Clin Cancer Res* 25(11):3266–3275. <https://doi.org/10.1158/1078-0432.CCR-18-2495>
  56. Yachida S, Jones S, Bozic I, Antal T, Leary R, Fu B, Kamiyama M, Hruban RH, Eshleman JR, Nowak MA, Velculescu VE, Kinzler KW, Vogelstein B, Jacobuzio-Donahue CA (2010) Distant metastasis occurs late during the genetic evolution of pancreatic cancer. *Nature* 467(7319):1114–1117. <https://doi.org/10.1038/nature09515>

## Diagnostic imaging and the use of artificial intelligence in the management of organ metastasis

Diagnostic imaging plays a significant role in detecting primary tumours and potential metastases. According to the current guidelines, contrast-enhanced computed tomography (CE-CT) is used for this purpose, with magnetic resonance imaging (MRI) as a complementary method for assessing anatomical structures like the brain. However, differential diagnosis is a daily challenge for radiologists. The use of artificial intelligence (AI) to optimise workflows, support image reporting and assess therapy outcomes in terms of therapeutic relevance is imperative. Radiomics refers to the computer-assisted extraction and analysis of a large number of quantitative features from radiological images using AI. Numerous studies have shown that radiomics facilitates the discovery of imaging biomarkers for outcome prediction in cancer patients. Interdisciplinary collaboration is essential in this context.

### Keywords

Radiology · Radiomics · Metastasis risk prediction · Differential diagnosis · Computer assisted diagnosis

57. Zech CJ, Schwenke C, Endrikat J (2019) Diagnostic efficacy and safety of gadoxetate disodium vs gadobenate dimeglumine in patients with known or suspected focal liver lesions: results of a clinical phase III study. *Magn Reson Insights* 12:1178623X19827976. <https://doi.org/10.1177/1178623X19827976>
58. Zhou Z, Siddiquee MMR, Tajbakhsh N, Liang J (2018) UNet++: a nested U-net architecture for medical image segmentation. *Deep learning in medical image analysis and multimodal learning for clinical decision support*. 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, held in conjunction with MICCAI 2018, Granada, S 3–11 [https://doi.org/10.1007/978-3-030-00889-5\\_1](https://doi.org/10.1007/978-3-030-00889-5_1)
59. Zwanenburg A, Vallières M, Abdalah MA, Aerts HJWL, Andrearczyk V, Apte A, Ashrafinia S, Bakas S, Beukinga RJ, Boellaard R, Bogowicz M, Boldrini L, Buvat I, Cook GJR, Davatzikos C, Depeursinge A, Desserot MC, Dinapoli N, Dinh CV, Echegaray S, Löck S (2020) The image biomarker standardization initiative: standardized quantitative radiomics for high-throughput image-based phenotyping. *Radiology* 295(2):328–338. <https://doi.org/10.1148/radiol.2020191145>