

FIȘĂ DOCUMENTARĂ

Emerging Applications of Deep Learning in Bone Tumors: Current Advances and Challenges

Aplicații emergente ale învățării profunde în tumorile osoase: progrese și provocări actuale

DATE GENERALE ALE SURSEI

Titlul documentului	Emerging Applications of Deep Learning in Bone Tumors: Current Advances and Challenges
Autori	Xiaowen Zhou, Hua Wang, Chengyao Feng, Ruilin Xu, Yu He, Lan Li, Chao Tu
Afilieri instituționale	Department of Orthopedics, The Second Xiangya Hospital of Central South University, Changsha, China
Anul publicării	2022 (publicat 19 iulie 2022)
Tip document	Articol de sinteză (review) — jurnal peer-reviewed
Jurnal / Editor	Frontiers in Oncology (Front Oncol); DOI: 10.3389/fonc.2022.908873; PMID: 35928860
Cuvinte cheie	tumoră osoasă, sarcom, învățare profundă, inteligență artificială, CNN, rețea neuronală convoluțională

OBIECTIVUL ȘI SCOPUL DOCUMENTULUI

Articolul analizează rolul **inteligenței artificiale bazate pe deep learning (DL)** în diagnosticul și managementul tumorilor osoase primare și metastatice. Modelele DL, în special rețelele neuronale convoluționale (CNN), au demonstrat performanțe comparabile sau superioare specialiștilor în interpretarea **imaginilor radiologice și histopatologice**. Articolul trece în revistă arhitecturile utilizate, fluxul de dezvoltare al modelelor, aplicațiile clinice demonstrate și limitările actuale, oferind o perspectivă integrată asupra potențialului și provocărilor AI în oncologia musculo-scheletală.

DATE RELEVANTE PENTRU SETUL DE INSTRUMENTE DE PRACTICĂ MEDICALĂ

Cele mai importante date și idei care pot fi preluate în setul de instrumente de practică medicală elaborat în cadrul proiectului, cu relevanță pentru grupul țintă din România:

1. Context clinic și relevanță

Tumorile osoase reprezintă un grup heterogen de afecțiuni care includ **tumori benigne, intermediare și maligne, precum și metastaze osoase**. Deși relativ rare (**2–3 cazuri/100.000 locuitori/an**), acestea implică o morbiditate și mortalitate importante, în special în cazul osteosarcomului, cea mai frecventă tumoră osoasă malignă primară la copii și adolescenți.

Diagnosticul actual necesită integrarea:

- anamnezei și examenului clinic;
- radiografiei convenționale;
- CT și RMN;
- examenului anatomopatologic și imunohistochimic.

Procesul **este complex, costisitor și dependent de experiența radiologului, ortopedului oncolog și anatomopatologului**. În acest context, **inteligența artificială (AI)**, în special **deep learning (DL)**, este investigată ca **instrument de suport decizional** capabil să reducă variabilitatea inter-observator și să crească acuratețea diagnosticului.

2. Fundamentele deep learning în imagistica oncologică

Deep learning reprezintă o ramură a machine learning-ului bazată pe rețele neuronale artificiale cu multiple straturi. În imagistica medicală, arhitectura predominantă este reprezentată de **rețelele neuronale convoluționale (CNN)**, care permit:

- extracția automată a caracteristicilor imagistice;
- eliminarea necesității definirii manuale a descriptorilor radiomici;
- identificarea unor pattern-uri imposibil de detectat vizual de către examinatori.

Cele mai frecvent utilizate arhitecturi: **AlexNet, VGGNet, ResNet, DenseNet, EfficientNet, U-Net** și variantele sale pentru segmentare.

3. Fluxul de dezvoltare al unui model DL

3.1 Preprocesarea datelor

Etapa critică pentru performanța modelului. Include standardizarea imaginilor (normalizarea intensităților, uniformizarea rezoluției, reducerea artefactelor), delimitarea regiunilor de interes (ROI) — manuală, semi-automată sau automată — și augmentarea datelor (rotații, ogindiri, transformări geometrice, GAN) pentru combaterea dimensiunilor reduse ale loturilor. Adnotarea constituie standardul de aur și necesită radiologi musculoscheletali, anatomopatologi specializați și chirurghi ortopezi oncologi — reprezentând principalul factor limitativ al dezvoltării modelelor.

3.2 Antrenarea modelului

Datele sunt împărțite în: set de antrenament (~70%), validare (~20%) și test (~10%). Principalele probleme includ overfitting, dezechilibrul claselor și lipsa generalizării multicentrice. Pentru optimizare sunt utilizate: dropout, batch normalization, transfer learning.

3.3 Evaluarea performanței

Parametru	Semnificație clinică
Sensibilitate	Capacitatea de a detecta boala
Specificitate	Excluderea cazurilor sănătoase
Precizie	Proporția rezultatelor pozitive corecte
Acuratețe	Clasificare globală
F1-score	Echilibru între sensibilitate și precizie
AUC-ROC	Capacitate discriminativă generală

4. Aplicații clinice în tumorile osoase primare

4.1 Detectarea și clasificarea tumorilor

Modalitate	Date / model utilizat	Rezultate
Radiografii convenționale	He et al.: 2899 radiografii, 1356 pacienți	AUC benign/malign: 0,877–0,916; acuratețe 3 categorii: 72,1%
Tumori genunchi	Multi-Level Seg-Unet; 1576 radiografii	Acuratețe 99,05% — potențial pentru screening automat
CT	Modele radiomice și DL pentru tumori sacrale	AUC $\approx$ 0,83–0,84
RMN	EfficientNet; evaluare extensie medulară, țesuturi moi	Sensibilitate 79%; specificitate 75%; AUC 0,82 — performanță apropiată de experții MSK

5. Segmentarea tumorală și volumetria

Segmentarea automată este esențială pentru **planificarea rezecției, monitorizarea răspunsului terapeutic și calculul încărcăturii tumorale**.

- Osteosarcom CT — MSFCN: Dice Similarity Coefficient (DSC): 87,8%; sensibilitate: 86,9%; F1-score: 0,908.
- Tumori pelvine RMN — model multiview cu segmentare pseudo-3D: reducerea timpului de segmentare de ~100 ori față de metodele convenționale.

6. Gradarea tumorală

Gradul histologic reprezintă unul dintre cei mai importanți factori prognostici. Un model DL bazat pe RMN a demonstrat diferențierea G1 versus G2/G3 cu **F1-score = 0,90 și AUC = 0,76**. Posibilitatea estimării noninvazive a gradului tumoral ar putea reduce necesitatea biopsiilor multiple.

7. Evaluarea răspunsului la chimioterapie

În osteosarcom, **≥90% necroză tumorală = răspuns bun; <90% necroză = răspuns slab**. Evaluarea actuală este exclusiv anatomopatologică. Modelele bazate pe RMN multiparametric și PET/CT cu 18F-FDG pot estima preoperator procentul de necroză și răspunsul la chimioterapia neoadjuvantă, permițând adaptarea precoce a schemelor terapeutice și identificarea nonresponderilor înainte de intervenția chirurgicală.

8. Predicția prognosticului

Modelul CNN pentru tumorile gigantocelulare osoase (GCTB) a demonstrat predicția recidivei locale după chiuretaj cu **sensibilitate 85,7%**. Integrarea localizării, vârstei și predicției CNN a crescut sensibilitatea la **87,5%**, depășind semnificativ performanța radiologilor umani.

9. Metastazele osoase

Modalitate	Aplicații	Performanțe raportate
Scintigrafie osoasă	Detectarea automată a leziunilor; diferențierea metastazelor de modificările degenerative	Acuratețe 91–97%; AUC până la 0,98; sensibilitate până la 93%
CT și RMN	Identificarea metastazelor vertebrale; segmentare automată; calcul volumetric	Sensibilitate până la 92%; acuratețe >92%
DCE-RMN	Identificarea tumorii primare (cancer pulmonar vs. alte tumori)	Acuratețe ~81%

10. Anatomie patologică digitală

Pe lame H&E digitalizate, DL poate diferenția țesut normal, tumoră viabilă și necroză tumorală cu **acuratețe 91–95% și F1-score până la 95%**. În sarcoame, DL poate genera hărți de activare care evidențiază zonele asociate cu prognostic nefavorabil (infiltrat limfocitar redus, hemoragie intratumorală, vascularizație tumorală crescută, stromă extracelulară abundentă).

11. Limitări majore

Probleme metodologice:

- loturi mici și lipsa validării externe;
- heterogenitatea protocoalelor imagistice;
- lipsa integrării datelor multimodale.

Probleme clinice:

- absența studiilor prospective;
- aplicabilitate clinică limitată în practica de rutină.

Probleme etice:

- confidențialitatea datelor pacienților;
- transparența algoritmilor ("cutia neagră");
- responsabilitatea decizională în caz de eroare.

Perspective pentru practica oncologică

Cele mai promițătoare direcții sunt:

- Modele multimodale — integrarea imagisticii cu histopatologia, datele clinice și genomica;
- Predicția moleculară — expresie genică, profiluri transcriptomice, biomarkeri prognostici;
- Detectarea metastazelor pulmonare — principala cauză de mortalitate în osteosarcom;
- Integrarea în fluxul clinic — sisteme de suport decizional pentru radiologi, ortopezi oncologi și anatomopatologi.

Concluzie

Datele actuale arată că **deep learning a depășit stadiul experimental de principiu** și demonstrează performanțe comparabile cu expertii în clasificarea, segmentarea, cuantificarea volumetrică, evaluarea răspunsului terapeutic și predicția prognosticului tumorilor osoase. Totuși, lipsa cohortelor multicentrice mari și a validării prospective împiedică, deocamdată, integrarea largă în practica clinică de rutină. Combinarea modelelor multimodale cu medicina personalizată și integrarea în sisteme de suport decizional reprezintă direcția viitoare prioritară.

Studiu integral poate fi consultat aici: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9345628/>

Front Oncol. 2022 Jul 19;12:908873. doi: [10.3389/fonc.2022.908873](https://doi.org/10.3389/fonc.2022.908873)

Emerging Applications of Deep Learning in Bone Tumors: Current Advances and Challenges

Xiaowen Zhou^{1,2}, Hua Wang², Chengyao Feng^{1,3}, Ruilin Xu^{1,3}, Yu He⁴, Lan Li⁵, Chao Tu^{1,3,*}

Author information Article notes Copyright and License information

PMCID: PMC9345628 PMID: [35928860](https://pubmed.ncbi.nlm.nih.gov/35928860/)

Abstract

Deep learning is a subfield of state-of-the-art artificial intelligence (AI) technology, and multiple deep learning-based AI models have been applied to musculoskeletal diseases. Deep learning has shown the capability to assist clinical diagnosis and prognosis prediction in a spectrum of musculoskeletal disorders, including fracture detection, cartilage and spinal lesions identification, and osteoarthritis severity assessment. Meanwhile, deep learning has also been extensively explored in diverse tumors such as prostate, breast, and lung cancers. Recently, the application of deep learning emerges in bone tumors. A growing number of deep learning models have demonstrated good performance in detection, segmentation, classification, volume calculation, grading, and assessment of tumor necrosis rate in primary and metastatic bone tumors based on both radiological (such as X-ray, CT, MRI, SPECT) and pathological images, implicating a potential for diagnosis assistance and prognosis

Collections

Permalink

RESOURCES

Similar articles

Cited by other articles

Links to NCBI Databases

ON THIS PAGE

Abstract

- 1 Introduction
- 2 Artificial intelligence based c
- 3 Workflow for building a deep
- 4 Deep learning applications i
- 5 Remaining limitations and fi
- 6 Conclusion

Author Contributions