

The Role of Image Processing and Machine Learning in the Transformation of Medical Diagnostics

Farzan Madadzadeh^{1,2}, Mohammad Mahdi Ghaemi¹, Zhila Agharezaei^{1*}

1. Medical Informatics Research Center, Institute for Futures Studies in Health, Kerman University of Medical Sciences, Kerman, Iran
2. Modeling in Health Research Center, Institute for Futures Studies in Health, Kerman University of Medical Sciences, Kerman, Iran

ARTICLE INFO:

Article History:

Received: 19 Apr 2026

Accepted: 19 May 2026

Published: 21 Jun 2026

*Corresponding Author:

Email:

Zh.agharezaei@gmail.com

Citation: Madadzadeh F, Mohammad Ghaemi M, Agharezaei Z. The Role of Image Processing and Machine Learning in the Transformation of Medical Diagnostics. *Journal of Health and Biomedical Informatics* 2026; 13(1): 59-63. [In Persian]

© 2026 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite



CrossMark

مقاله نامه به سردبیر

نقش پردازش تصویر و یادگیری ماشین در تحول تشخیص‌های پزشکی

فرزان مددی زاده^{۱،۲}، محمد مهدی قائمی^۱، ژילה آقارضائی^{*}

۱. مرکز تحقیقات انفورماتیک پزشکی، پژوهشکده آینده پژوهی در سلامت، دانشگاه علوم پزشکی کرمان، کرمان، ایران

۲. مرکز تحقیقات مدل‌سازی در سلامت، پژوهشکده آینده پژوهی در سلامت، دانشگاه علوم پزشکی کرمان، کرمان، ایران

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۵/۱/۳۰

پذیرش: ۱۴۰۵/۲/۲۹

انتشار برخط: ۱۴۰۵/۳/۳۱

*نویسنده مسئول:

ژילה آقارضائی

ایمیل:

Zh.agharezaei@gmail.com

ارجاع:

مددی زاده فرزان، قائمی محمد مهدی، آقارضائی ژילה. نقش پردازش تصویر و یادگیری ماشین در تحول تشخیص‌های پزشکی. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۵؛ ۱۳(۱): ۵۹-۶۳.

مقدمه

پیشرفت‌های سریع در حوزه فناوری اطلاعات و هوش مصنوعی، به‌ویژه در شاخه‌های پردازش تصویر و یادگیری ماشین، افق‌های تازه‌ای در علوم پزشکی گشوده است [۱]. امروزه تصاویر پزشکی نظیر رادیوگرافی، ماموگرافی، سونوگرافی، تصاویر تشدید مغناطیسی Magnetic Resonance Imaging و توموگرافی کامپیوتری Computed Tomography، بخش جدایی‌ناپذیری از فرآیند تشخیص، پیگیری درمان و پیش‌آگهی بیماری‌ها به‌شمار می‌روند [۲، ۳]. با این حال، تفسیر دستی این تصاویر توسط متخصصان رادیولوژی، کاری زمان‌بر، تا حدی سلیقه‌ای و مستعد خطاهای انسانی است [۱، ۲]. در این میان، الگوریتم‌های یادگیری ماشین با قابلیت استخراج خودکار الگوهای پیچیده و تشخیص ناهنجاری‌های ظریف، می‌توانند به‌عنوان ابزاری کمکی و قدرتمند، دقت و سرعت تشخیص را به‌طور چشمگیری افزایش دهند. به‌کارگیری این روش‌ها نه تنها بار کاری پزشکان را کاهش می‌دهد، بلکه در مناطق محروم و کم‌برخوردار که دسترسی به رادیولوژیست مجرب محدود است، امکان غربالگری انبوه و تشخیص زودهنگام را فراهم می‌آورد [۳].

در دهه گذشته، روش‌های یادگیری ماشین از رویکردهای مبتنی بر استخراج دستی ویژگی (همچون ماشین بردار پشتیبان Support Vector Machine و جنگل تصادفی Random Forest) به‌سوی معماری‌های یادگیری عمیق حرکت کرده‌اند [۴]. شبکه‌های عصبی کانولوشنی Convolutional Neural Network به‌عنوان قلب تپنده تحلیل تصاویر پزشکی مدرن شناخته می‌شوند؛ این شبکه‌ها با الهام از سیستم بینایی زیستی، قادرند لایه‌به‌لایه ویژگی‌ها را از سطوح ساده (مانند لبه‌ها و بافت‌ها) تا مفاهیم انتزاعی مرتبط با پاتولوژی، به‌صورت خودکار بیاموزند [۵]. برای نمونه، معماری‌هایی نظیر U-Net، ResNet، Xception، MobileNet و Mask R-CNN برای وظایف گوناگونی چون قطعه‌بندی دقیق تومورها، رگ‌های خونی و لندام‌ها طراحی شده‌اند. افزون بر این، روش‌های یادگیری انتقالی با بهره‌گیری از مدل‌های از پیش‌آموزش‌دیده روی مجموعه‌داده‌های عظیمی همچون ImageNet، توانسته‌اند مشکل کمبود داده‌های برچسب‌خورده پزشکی را تا حد زیادی مرتفع سازند [۸-۵]. برای آشنایی بیشتر با نقاط قوت و ضعف هر یک از این رویکردها، خلاصه‌ای از آن‌ها در جدول ۱ ارائه شده است. همچنین، ظهور یادگیری چندوجهی و به‌کارگیری معماری‌های ترانسفورمر در تصاویر سه‌بعدی و ویدئوهای پزشکی، مرزهای دقت تشخیص را جابه‌جا کرده است. با توجه به اهمیت توضیح‌پذیری (Explainability) و کاهش سوگیری الگوریتمی، گام بعدی برای پذیرش گسترده این فناوری در بالین بیمار، طراحی داشبوردهای تعاملی بالینی مبتنی بر شواهد است؛ داشبوردهایی که هم دلایل خروجی مدل را به زبان پزشک ترجمه کنند و هم نقاط کور داده‌ای (از جمله کمبود نمایندگی گروه‌های نژادی یا سنی) را به‌صورت هشدارهای بصری نمایش دهند [۷، ۵، ۴].

جدول ۱: خلاصه روش‌های رایج یادگیری ماشین در پردازش تصاویر پزشکی و نقاط قوت و ضعف آنها

روش (Method)	نقاط قوت (Strengths)	نقاط ضعف (Weaknesses)
شبکه‌های عصبی کانولوشنی [۵] (CNN)	استخراج خودکار ویژگی‌های سلسله‌مراتبی، دقت بالا در طبقه‌بندی و تشخیص ضایعات؛ مناسب برای تصاویر دوبعدی	نیاز به داده‌های حجیم برچسب‌خورده، هزینه محاسباتی بالا؛ تفسیرپذیری دشوار (جعبه سیاه)
شبکه‌های [۶، ۷] U-Net، MobileNet، Xception، ResNet	معماری ایده‌آل برای قطعه‌بندی دقیق (مثلاً تومورها و اندام‌ها، عملکرد خوب حتی با داده‌های نسبتاً کم)	پایداری پایین در برابر نویزهای شدید تصویر، دشواری در قطعه‌بندی اشیاء با اندازه‌های بسیار متفاوت
یادگیری انتقالی [۷، ۸] (Transfer Learning)	کاهش چشمگیر نیاز به داده و زمان آموزش، بهره‌گیری از دانش مدل‌های آموزش‌دیده روی مجموعه‌های عظیم	خطر انتقال سوگیری‌های نامربوط از دامنه مبدأ؛ عملکرد ممکن است برای تصاویر بسیار تخصصی پزشکی بهینه نباشد
ماشین بردار پشتیبان [۴] (SVM)	عملکرد خوب در داده‌های کوچک و با ابعاد بالا، دارای مبنای ریاضی قوی و حافظه کارآمد	نیاز به استخراج دستی ویژگی‌ها، حساسیت به تنظیم پارامترها و مقیاس داده‌ها، عملکرد ضعیف در داده‌های تصویری خام
جنگل تصادفی [۴] (Random Forest)	مقاوم در برابر بیش‌برازش، امکان ارزیابی اهمیت ویژگی‌ها، پیاده‌سازی آسان	نیاز به استخراج دستی ویژگی‌ها؛ کارایی پایین با داده‌های ابعاد بسیار بالا (مثلاً تصاویر خام)



هرچند پتانسیل روش‌های یادگیری ماشین در پردازش تصاویر پزشکی غیرقابل انکار است، اما پیاده‌سازی بالینی آن‌ها با موانع جدی روبه‌روست. نخستین چالش، نیاز به مجموعه داده‌های بزرگ، برچسب‌خورده با کیفیت و همگن است؛ در حالی که داده‌های پزشکی اغلب محدود، نامتوازن و دارای تغییرات بین‌ناظری بالایی هستند [۳، ۵]. دومین مشکل، مسئله تعمیم‌پذیری (Generalization) است؛ مدلی که روی داده‌های یک دستگاه یا یک مرکز درمانی خاص آموزش دیده، ممکن است در مرکزی دیگر با افت شدید عملکرد مواجه شود [۲]. سومین چالش، ملاحظات اخلاقی، حریم خصوصی بیماران و مقاومت فرهنگی پزشکان در برابر پذیرش جعبه‌سیاه‌های هوش مصنوعی است [۷]. از سوی دیگر، الزامات سخت‌افزاری برای اجرای مدل‌های عمیق و نیاز به زیرساخت ابری یا محاسبات سریع، در بسیاری از بیمارستان‌های کشورهای در حال توسعه فراهم نیست. برای غلبه بر این موانع، راهکارهایی همچون یادگیری فدرال (برای آموزش بدون خروج داده از بیمارستان‌ها)، افزایش قابلیت توضیح‌پذیری با نقشه‌های توجه، و همکاری نزدیک میان مهندسان کامپیوتر، متخصصان رادیولوژی و انفورماتیک پزشکی ضروری به نظر می‌رسد. همچنین تدوین استانداردهای ملی برای برچسب‌زنی تصاویر و ایجاد بانک‌های اطلاعاتی غیرانتفاعی، گامی حیاتی در این مسیر به شمار می‌رود [۵، ۷].

در جمع‌بندی، باید تأکید کرد که ادغام روش‌های پیشرفته یادگیری ماشین با پردازش تصاویر پزشکی، هم‌اکنون در بسیاری از مراکز پیشرفته جهان در حال تغییر چهره تشخیص و درمان است. از تشخیص زودهنگام سرطان پستان در ماموگرافی تا قطعه‌بندی دقیق ضایعات مغزی در اسکن‌های Computed Tomography و تخمین و طبقه‌بندی ریسک در تصویربرداری Magnetic Resonance Imaging از دلول‌های تیروئید، شواهد محکمی از بهبود شاخص‌های حساسیت و ویژگی به نفع روش‌های هوشمند وجود دارد. با این حال، نباید فراموش کرد که هدف هرگز جایگزینی پزشک نیست، بلکه توانمندسازی او با ابزاری دقیق و سریع و به‌کارگیری سیستم‌های کمک تصمیم بالینی است.

تعارض منافع

بین نویسندگان هیچ گونه تعارض منافع وجود ندارد.

حمایت مالی

برای انجام این پژوهش حمایت مالی دریافت نشده است.

اعلام استفاده از هوش مصنوعی (AI)

از هوش مصنوعی استفاده نشده است.

سهام مشارکت نویسندگان

تمام نویسندگان به طور مساوی در نگارش مقاله مشارکت داشته‌اند.

References

- [1]. Garg P, Sharma MK, Kumar P. Transparency in diagnosis: unveiling the power of deep learning and explainable AI for medical image interpretation. *Arabian Journal for Science and Engineering* 2025;50(19):15751-67.
- [2]. Al-Zoghby AM, Ebada AI, Saleh AS, Abdelhay M, Awad WA. A comprehensive review of multimodal deep learning for enhanced medical diagnostics. *Computers, Materials & Continua*. 2025;84(3):4155-93. doi: 10.32604/cmc.2025.065571
- [3]. Lamba R. Advances in AI for medical imaging: a review of machine and deep learning in disease detection. *Procedia Computer Science* 2025;260:262-73. <https://doi.org/10.1016/j.procs.2025.03.201>

- [4]. Hamim SA, Aftab RS, Ahmed MM, Abdullah-Al-Jubair M, Mridha MF. Enhancing Medical Image Analysis with Advanced Optimization Techniques: A Comparative Study of Machine Learning Model Optimizers. In Nature-Inspired Approaches to Engineering and Healthcare Solutions. Switzerland: Springer; 2026. p. 247-64.
- [5]. Abdellaoui C, Belkacem S, Messaoudi N. Deep learning architectures for medical image segmentation: an organized analysis of CNN-based models and uses. Bulletin of Electrical Engineering and Informatics 2026;15(1):424-37. doi: <https://doi.org/10.11591/eei.v15i1.10839>
- [6]. Agharezaei Z, Shirshekar M, Firouzi R, Hassanzadeh S, Zarei-Ghanavati S, Bahaadinbeigy K, et al. A new morphological classification of keratoconus using few-shot learning in candidates for intrastromal corneal ring implants. Biomedical Signal Processing and Control. 2025;106:107664. <https://doi.org/10.1016/j.bspc.2025.107664>
- [7]. Xu Y, Khan TM, Song Y, Meijering E. Edge deep learning in computer vision and medical diagnostics: a comprehensive survey. arXiv preprint arXiv:2605.06714. 2026.
- [8]. Agharezaei Z, Firouzi R, Hassanzadeh S, Zarei-Ghanavati S, Bahaadinbeigy K, Golabpour A, et al. Computer-aided diagnosis of keratoconus through VAE-augmented images using deep learning. Scientific Reports 2023;13(1):20586. <https://doi.org/10.1038/s41598-023-46903-5>