



YAPAY ZEKÂ DESTEKLİ KLİNİK EĞİTİM VE SİMÜLASYON SİSTEMLERİ

Büşra EMİR¹

GİRİŞ

Acil tıp, hızlı karar alma ve etkin müdahale gerektiren dinamik bir tıp alanıdır. Son yıllarda yapay zekâ (YZ) teknolojileri sağlık alanında büyük gelişme göstermiş ve acil tıp pratiğinde ve eğitiminde köklü değişim potansiyeli yaratmıştır. COVID-19 pandemisiyle artan iş yükü ve eğitim kısıtları, yeni çözümlere ihtiyaç duyulduğunu ortaya koymuştur. YZ, acil serviste triyaj, tanı, tedavi karar desteği ve eğitim süreçlerinde dönüşüm vadeden bir araç olarak öne çıkmaktadır (1). Güncel derleme çalışmaları, YZ tabanlı sistemlerin acil radyoloji görüntülerindeki hastalık tespitinde %85–90 doğruluk sağladığını, YZ destekli triyaj sistemlerinin yüksek ve düşük aciliyet düzeylerini sınıflandırabildiğini, eğitim alanında ise büyük dil modellerinin (ChatGPT, Gemini, CoPilot, vb.) acil tıp sınavlarını yüksek doğrulukla değerlendirebildiğini ortaya koymaktadır. Bununla birlikte, YZ modellerinin klinik iş akışına entegrasyonu ve genelleme kapasitesi konusunda hâlâ zorluklar mevcuttur (2). Yapay zekânın acil tıpta kullanım alanları hızla genişlemektedir. Triage, görüntüleme, hasta sonuç tahmini gibi konularda makine öğrenmesi ve derin öğrenme teknikleri kullanılarak gerçekleştirilen ça-

¹ Dr. Öğr. Üyesi, İzmir Kâtip Çelebi Üniversitesi, Tıp Fakültesi, Temel Tıp Bilimleri Bölümü, Biyoistatistik AD., busra.emir@ikcu.edu.tr, ORCID iD: 0000-0003-4694-1319
DOI: 10.37609/akya.63.c683

Yapay zekâ, rutin işleri ve hesaplamaları devraldığında, doktorlar hastalara daha fazla zaman ayırıp onları rahatlatma, doğru bilgilendirme, psikolojik destek verme gibi yönlerle odaklanabilir. Bu açıdan yapay zekâ, hekimleri “insanileştirme” fırsatı da sunabilir. Makinelerin yapamadığını yapmaya yönlendirebilir. Eğitim açısından, yapay zekâ okuryazarlığı geleceğin zorunlu bir parçası olacaktır. Tıp fakültelerinin müfredatlarına veri bilimi, istatistik ve yapay zekâ ile ilgili temel dersleri eklemesi önemlidir (45). Acil tıp asistanları da uzmanlık eğitimleri boyunca yapay zekâ destekli simülasyonlar, dijital sınavlar ve YZ rehberli öğrenme modülleriyle karşılaşmaya hazırlanmalıdır. Bu sayede uzmanlık sonrasında da bu teknolojilere aşina olarak çalışma hayatına atılacaklardır. Sürekli tıp eğitiminde de benzer şekilde hekimlere yönelik yapay zekâ kullanım kursları, atölyeler ve eğitimler düzenlenmesi faydalı olacaktır. Yapay zekâ destekli klinik eğitim ve simülasyon sistemleri acil tıpta heyecan verici ufuklar açmaktadır. Bu teknolojilerin doğru entegrasyonu sağlandığında, acil hasta bakım kalitesini artırması, tanı tedavi süreçlerini hızlandırması ve sağlık çalışanlarının eğitimini zenginleştirilmesi beklenmektedir. Teknolojinin kendi başına bir amaç değil, daha iyi sağlık hizmeti için bir araç olduğu unutulmamalıdır. Yapay zekâ ile insan zekâsının en iyi yönleri bir araya getirilebilirse hem hastalar hem de sağlık çalışanları için daha güvenli, etkin ve verimli bir acil bakım ortamı oluşturulabilir. Gelecekte acil servislerde yapay zekâ uygulamalarının başarısı, bu sistemlerin çok disiplinli iş birliğiyle geliştirilmesine, etik ilkesel çerçevede kullanılmasına ve sonuçlarının sürekli izlenerek iyileştirilmesine bağlı olacaktır.

KAYNAKLAR

1. Kirubarajan A, Taher A, Khan S, Masood S. Artificial intelligence in emergency medicine: a scoping review. *J Am Coll Emerg Physicians Open*. 2020;1(6):1691–1702. doi:10.1002/emp2.12277
2. Berikol G, Kanbakan A, Ilhan B, Doğanay F. Mapping artificial intelligence models in emergency medicine: a scoping review on artificial intelligence performance in emergency care and education. *Turk J Emerg Med*. 2025;25. doi:10.4103/tjem.tjem_45_25
3. Naik VN, Brien SE. Simulation: a means to address and improve patient safety. *Can J Anaesth*. 2013;60:192–200. doi:10.1007/s12630-012-9860-z
4. Komasa N, Berg BW. Interprofessional simulation training for perioperative management team development and patient safety. *J Perioper Pract*. 2016;26:250–253. doi:10.1177/175045891602601103
5. Davitadze M, Ooi E, Ng CY, et al. SIMBA: using Kolb's learning theory in simulation-based learning to improve participants' confidence. *BMC Med Educ*. 2022;22:116. doi:10.1186/s12909-022-03176-2
6. Bienstock J, Heuer A. A review on the evolution of simulation-based training to help build a safer future. *Medicine (Baltimore)*. 2022;101:0. doi:10.1097/MD.0000000000029503

7. Komasaawa N, Yokohira M. Simulation-based education in the artificial intelligence era. *Cureus*. 2023;15(6):e40940. doi:10.7759/cureus.40940
8. HealthySimulation.com. SimConverse: Conversational AI for Healthcare Simulation. Published June 21, 2023. Accessed July 9, 2025. <https://www.healthysimulation.com/medicalsimulation/vendors/simconverse/>
9. Gore T. Lumeto introduces InvolveXR AI Characters: the first customizable AI-enabled virtual patients. *HealthySimulation.com*. Published October 22, 2024. Accessed July 9, 2025. <https://www.healthysimulation.com/lumeto-involvexr-customizable-ai-virtual-patients/>
10. Zidoun Y, Mardi AE. Artificial intelligence (AI)-based simulators versus simulated patients in undergraduate programs: a protocol for a randomized controlled trial. *BMC Med Educ*. 2024;24(1):1260. doi:10.1186/s12909-024-06236-x
11. Mangano A, Valle V, Dreifuss NH, Aguiluz G, Masrur MA. Role of artificial intelligence (AI) in surgery: introduction, general principles, and potential applications. *Surg Technol Int*. 2020;38:17–21. doi:10.52198/21.STI.38.SO1369
12. Abd-Alrazaq A, Abuelezz I, Hassan A, et al. Artificial intelligence-driven serious games in health care: scoping review. *JMIR Serious Games*. 2022;10(4):e39840. doi:10.2196/39840
13. Wang L, Mao Y, Wang L, Sun Y, Song J, Zhang Y. Suitability of GPT-4o as an evaluator of cardiopulmonary resuscitation skills examinations. *Resuscitation*. 2024;204:110404. doi:10.1016/j.resuscitation.2024.110404
14. Ahuja V, Nair LV. Artificial intelligence and technology in COVID era: a narrative review. *J Anaesthesiol Clin Pharmacol*. 2021;37(1):28–34. doi:10.4103/joacp.JOACP_558_20
15. Chenais G, Lagarde E, Gil-Jardiné C. Artificial intelligence in emergency medicine: viewpoint of current applications and foreseeable opportunities and challenges. *J Med Internet Res*. 2023;25:e40031. doi:10.2196/40031
16. Christ M, Grossmann F, Winter D, Bingisser R, Platz E. Modern triage in the emergency department. *Dtsch Arztebl Int*. 2010;107(50):892–898. doi:10.3238/arztebl.2010.0892
17. Nasser L, McLeod SL, Hall JN. Evaluating the reliability of a remote acuity prediction tool in a Canadian academic emergency department. *Ann Emerg Med*. 2024;83(4):373–379. doi:10.1016/j.annemergmed.2023.11.018
18. El Ariss AB, Kijpaisalratana N, Ahmed S, et al. Development and validation of a machine learning framework for improved resource allocation in the emergency department. *Am J Emerg Med*. 2024;84:141–148. doi:10.1016/j.ajem.2024.07.040
19. Xu Y, Malik N, Chernbumroong S, et al. Triage in major incidents: development and external validation of novel machine learning derived primary and secondary triage tools. *Emerg Med J*. 2024;41:176–183. doi:10.1136/emermed-2022-212440
20. Davoudi A, Chae S, Evans L, et al. Fairness gaps in machine learning models for hospitalization and emergency department visit risk prediction in home healthcare patients with heart failure. *Int J Med Inform*. 2024;191:105534. doi:10.1016/j.ijmedinf.2024.105534
21. Ivanov O, Wolf L, Brecher D, et al. Improving ED emergency severity index acuity assignment using machine learning and clinical natural language processing. *J Emerg Nurs*. 2021;47(2):265–278.e7. doi:10.1016/j.jen.2020.11.001
22. Chen T, Guestrin C. XGBoost: a scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*; August 2016; San Francisco, CA. p. 785–794.
23. Gharehchopogh FS, Khalifelu ZA. Analysis and evaluation of unstructured data: text mining versus natural language processing. In: *2011 5th International Conference on Application of Information and Communication Technologies (AICT)*. IEEE; 2011:1–4.
24. Zhang X, Wang Y, Jiang Y, Pacella CB, Zhang W. Integrating structured and unstructured data

- for predicting emergency severity: an association and predictive study using transformer-based natural language processing models. *BMC Med Inform Decis Mak.* 2024;24(372):1–13. doi:10.1186/s12911-024-02793-9
25. Patel D, Timsina P, Gorenstein L, et al. Traditional machine learning, deep learning, and BERT (large language model) approaches for predicting hospitalizations from nurse triage notes: comparative evaluation of resource management. *JMIR AI.* 2024;3(1): e52190. doi:10.2196/52190
 26. Weidman AC, Sedor-Schiffhauer Z, Zikmund C, et al. Words to live by: using medic impressions to identify the need for prehospital lifesaving interventions. *Acad Emerg Med.* 2025;32(5):516–525. doi:10.1111/acem.15067
 27. Saggu S, Daneshvar H, Samavi R, et al. Prediction of emergency department revisits among child and youth mental health outpatients using deep learning techniques. *BMC Med Inform Decis Mak.* 2024;24(1):42. doi:10.1186/s12911-024-02450-1
 28. Lee S, Mohr NM, Street WN, Nadkarni P. Machine learning in relation to emergency medicine clinical and operational scenarios: an overview. *West J Emerg Med.* 2019;20(2):219–227. doi:10.5811/westjem.2019.1.41244
 29. Wardlaw JM, Mair G, von Kummer R, et al. Accuracy of automated computer-aided diagnosis for stroke imaging: a critical evaluation of current evidence. *Stroke.* 2022;53(7):2393–2403. doi:10.1161/STROKEAHA.121.036204
 30. Zhang C, Peng J, Wang L, et al. A deep learning-powered diagnostic model for acute pancreatitis. *BMC Med Imaging.* 2024;24:154. doi:10.1186/s12880-024-01339-9
 31. Song YF, Huang HN, Ma JJ, et al. Early prediction of sepsis in emergency department patients using various methods and scoring systems. *Nurs Crit Care.* 2025;30(3):e13201. doi:10.1111/nicc.13201
 32. Aygun U, Yagin FH, Yagin B, et al. Assessment of sepsis risk at admission to the emergency department: clinical interpretable prediction model. *Diagnostics (Basel).* 2024;14(5):457. doi:10.3390/diagnostics14050457
 33. Iftikhar H, Anjum S, Bhutta ZA, Najam M, Bashir K. Performance of ChatGPT in emergency medicine residency exams in Qatar: a comparative analysis with resident physicians. *Qatar Med J.* 2024;2024(4):61. doi:10.5339/qmj.2024.61
 34. Colacca C, Ergin M, Ozensoy HS, et al. Emergency department triaging using ChatGPT based on emergency-severity index principles: a cross-sectional study. *Sci Rep.* 2024;14(1):22106. doi:10.1038/s41598-024-73229-7
 35. Ao G, Chen M, Li J, et al. Comparative analysis of large language models on rare disease identification. *Orphanet J Rare Dis.* 2025;20:150. doi:10.1186/s13023-025-03656-w
 36. Chang CH, Nguyen PA, Huang CC, et al. Acute myocardial infarction risk prediction in emergency chest pain patients: an external validation study. *Int J Med Inform.* 2025;193:105683. doi:10.1016/j.ijmedinf.2024.105683
 37. Lee SH, Hong WP, Kim J, Cho Y, Lee E. Smartphone AI vs. medical experts: a comparative study in prehospital STEMI diagnosis. *Yonsei Med J.* 2024;65(3):174–180. doi:10.3349/ymj.2023.0341
 38. Sen A, Navarro L, Avril S, Aguirre M. A data-driven computational methodology towards a prehospital acute ischaemic stroke screening tool using haemodynamics waveforms. *Comput Methods Programs Biomed.* 2024;244:107982. doi:10.1016/j.cmpb.2023.107982
 39. Ferri P, Sáez C, Félix-De Castro A, et al. Deep ensemble multitask classification of emergency medical call incidents combining multimodal data improves emergency medical dispatch. *Artif Intell Med.* 2021;117:102088. doi:10.1016/j.artmed.2021.102088
 40. Elayan H, Aloqaily M, Guizani M. Digital twin for intelligent context-aware IoT healthcare systems. *IEEE Internet Things J.* 2021;8(23):16749–16757. doi:10.1109/JIOT.2021.3051158
 41. Boulos MN, Brewer AC, Karimkhani C, Buller DB, Dellavalle RP. Mobile medical and health

- apps: state of the art, concerns, regulatory control and certification. *Online J Public Health Inform.* 2014;5(3):229. doi:10.5210/ojphi.v5i3.4814
42. Schnapp B, Sehdev M, Schrepel C, et al. ChatG-PD? Comparing large language model artificial intelligence and faculty rankings of the competitiveness of standardized letters of evaluation. *AEM Educ Train.* 2024;8(6):e11052. doi:10.1002/aet2.11052
43. Misra SM, Suresh S. Artificial intelligence and objective structured clinical examinations: using ChatGPT to revolutionize clinical skills assessment in medical education. *J Med Educ Curric Dev.* 2024;11. doi:10.1177/23821205241263475
44. Karnan N, Francis J, Vijayvargiya I, et al. Analyzing the effectiveness of AI-generated patient education materials: a comparative study of ChatGPT and Google Gemini. *Cureus.* 2024;16(11):e74398. doi:10.7759/cureus.74398
45. de Bruijne M. Machine learning approaches in medical image analysis: from detection to diagnosis. *Med Image Anal.* 2016;33:94–97. doi:10.1016/j.media.2016.06.032
46. Mathews SC, McShea MJ, Hanley CL, Ravitz A, Labrique AB, Cohen AB. Digital health: a path to validation. *NPJ Digit Med.* 2019;38:1–9. doi:10.1038/s41746-019-0111-3
47. European Commission. Proposal for a directive of the European Parliament and of the Council on adapting non-contractual civil liability rules to artificial intelligence (AI Liability Directive). Published September 28, 2022. Accessed July 9, 2025. https://commission.europa.eu/system/files/2022-09/1_1_197605_prop_dir_ai_en.pdf
48. European Commission. New liability rules on products and artificial intelligence to protect consumers and foster innovation. Published September 28, 2022. Accessed July 9, 2025. https://ec.europa.eu/commission/presscorner/detail/en/ip_22_5807