

Acil Serviste Yapay Zekâ Uygulamaları ◀

Artificial Intelligence Applications in Emergency Service

Arif ERDOĞAN

ÖZ

Yapay zekâ ile yapılan araştırmalar son yıllarda önem kazanmıştır. Bu artışın nedenlerinin başında modern makine öğrenmesi tekniklerinden derin öğrenme, büyük veri kümelerinin kullanılabilirliği ve bilgi işlem gücündeki gelişmeler ile bu konularda artan başarılar yer almaktadır. Sağlık hizmetlerinde yapay zekânın uygulanabilirliği gösterilmiştir. Geliştirilen algoritmalar doktor performanslarıyla eş değer olabilmektedir ve hatta onları aşabilmektedir. Yapay zekâ tabanlı araçlar risk sınıflandırması, tanı ve tedavi seçimi dahil olmak üzere tipta çeşitli faktörleri tahmin etmek için kullanılmıştır. Yapay zekâ teknolojileri önumüzdeki yıllarda acil tıp alanında giderek daha fazla kullanılacaktır. Bu derlemenin amacı acil tıp ile ilgili olan mevcut yapay zekâ araştırmalarına genel bir bakış sağlamaktr.

Anahtar Kelimeler: Yapay zekâ, Derin öğrenme, Acil tıp, Makine öğrenmesi

ABSTRACT

Research with artificial intelligence has gained importance in recent years. The main reasons for this increase are modern machine learning techniques; deep learning, the availability of large datasets, and advances in computing power and increasing success in these areas. The applicability of artificial intelligence in healthcare has been demonstrated. Algorithms can equate to or even exceed physician performances. AI-based tools have been used to predict various factors in medicine, including risk stratification, diagnosis, and treatment selection. Artificial intelligence technologies will be used more and more in the field of emergency medicine in the coming years. The purpose of this review is to provide an overview of current artificial intelligence research related to emergency medicine.

Keywords: Artificial intelligence, Deep learning, Emergency medicine, Machine learning

Received / Geliş	25.09.2021
Accepted / Kabul	13.10.2021
Publication Date	27.12.2021

* Sorumlu Yazar
Corresponding Author

Arife Erdogan

İzmir Bakırçay Üniversitesi
Çигli Eğitim ve Araştırma Hastanesi,
Acil Tıp Anabilim Dalı, İzmir, Türkiye

 arife.erdogan@yahoo.com

ORCID: 0000-0003-2488-2012

Giriş

Yapay zekâ geleneksel bir tanım olarak, insan zekâsı gerektiren görevleri yerine getirebilen bilgisayar sistemleri şeklinde ifade edilebilmektedir (1). Yapay zekâ, makinelerin sorgulama yeteneğine, geçmiş bilgilerden yararlanabilme, öğrenme, planlama, iletişimini sağlama, algılama ve bunun yanı sıra makineleri kontrol ederek hareket etmeleri ve yer değiştirebilme yeteneğine sahip olmasını hedefleyen bir bilim dalıdır. Bunun için karar vermek ve problem çözmek gibi insan zekâsının yaptığı görevleri yerine getirebilen bilgisayar sistemleri geliştirilmeye çalışılmaktadır (2, 3). Makine öğrenmesi, sunulan kalıplara yanıt olarak kendilerini değiştirebilen ve yeni verilere uygulandığında çıkarımlar yapabilen algoritmalar oluşturarak bir yapay zekâ sisteminin geliştirilebileceği mekanizmadır (1, 4).

Bazı bilim insanları, yapay zekâ ile ilgili yapılan çalışmalar sonucunda elde edilecek ilerlemenin toplumları elektriğin bulunması kadar temelden dönüştüreceğini ileri sürmektedir. Son yıllarda bilgi işlem gücünün, verilerin depolanmasında ve bilginin sayısallaştırmasındaki artışlar, yapay zekanın mevcut büyümeyesine önemli oranda katkıda bulunmuştur (3). Yapay zekâ araştırmaları, sağlık alanında da yeni icatlar ve yenilikçi uygulamaları ortaya koymamak için yoğun şekilde devam etmektedir. Radyoloji, beyin cerrahisi, dermatoloji ve oftalmoloji dahil olmak üzere tıbbın çeşitli alanlarında, yapay zekânın alanındaki uzman hekim performanslarıyla eşit seviyelere geldiği hatta bazı durumlarda onların yeteneklerini de aşabildiği ve böylece sağlıkla ilgili birçok alanda yararlı olduğu kanıtlanmıştır (5-8). Buna ek olarak yapay zekâ tabanlı araçlar, risk sınıflandırması, tanı ve tedavi seçimi gibi tıp alanına ait önemli faktörleri tahminlemede kullanılmıştır (9, 10). Hastaları sınıflandırmak ve sonuçları tahminleyebilmek için klinik verileri hızlıca yorumlamak, maliyet, verimlilik ve hasta bakım kalitesi üzerinde doğrudan etkilerinin olduğu acil servis hizmetleri için oldukça önemli bir süreçtir. Acil servis hizmetlerinde, hasta bakım sürecinin neredeyse her adımını yapay zekâ temelli uygulamalara dönüştürmek için ciddi düzeyde bir potansiyel bulunmaktadır. Bu nedenlerle, yapay zekâ uygulamalarının acil servis hizmetlerini önemli ölçüde geliştirebilme potansiyeli görülmektedir.

Acil Serviste Kullanılan Yapay Zekâ Uygulamaları

Hastanelerin en önemli ve yoğun birimleri olan acil servisler, tıbbi hizmetin 7/24 sağlanmasında hayatı rol üstlenmektedirler. Acil servisler hasta yoğunluğunun ne zaman ortaya çıkacağı belirli olmayan ve karmaşıklığın oldukça fazla bulunduğu yerlerdir. Bu gibi nedenlerle acil servis hizmetlerinde çeşitli eksikliklerden dolayı bazı zorluklar yaşanmaktadır.

Yapay zekâ teknolojilerinin yakın gelecekte acil tıbbın birçok yönünü etkilemesi muhtemeldir. Acil servislerde kullanılabilecek yapay zeka örneklerinden bazılarını alttaki gibi sıralayabiliriz: Kardiyovasküler açıdan不稳定 olan hastalar, durumlarına kötüleşme olan hastalar için veya sepsisin erken tanınmasında kullanılabilcek doğru erken uyarı sistemi sağlayabilen algoritmalar, görüntüleme ve kan analizi sonuçlarının hızlı şekilde taranılmasını, triaj ve ön teşhisin benzer şekilde hızlı gerçekleştirilebilmesini sağlayan algoritmalar ile geleneksel ölçütlerden daha iyi performans gösteren sonuç tahminleri ve risk sınıflandırması gibi araçlar örneklenirilebilir.

Yapay zekânın acil serviste en çok kullanılan uygulamalarından birisi acil radyojisidir. Acil hekimlerinin en önemli ve zorlu görevlerinden biri yaşamı tehdit eden olayların radyolojik görüntüsünü hızlı bir şekilde değerlendirmek ve bir radyologun

incelemesinden önce bu acil bulgulara göre hareket edebilmektedir. Bundan dolayı acil yorumlama gerektiren akut bazı vakalarla ilgili çeşitli çalışmalar yapılmıştır. Örneğin kontrastsız beyin bilgisayarlı tomografi (BT) görüntülemeinden, kanama, kitle etkisi, hidrosefali, akut bölgelik enfarktüs, travmatik beyin hasarı ve orta hat kaymasını saptamak için çeşitli makine öğrenme algoritmaları geliştirilmiş ve test edilmiştir. Bu algoritmaların çoğu değerlendirildiğinde, %99'a varan negatif tahmin değerleri ile birlikte %94-100 arasında değişen hassasiyete sahiptirler ve acil müdahale gerektiren yaşamı tehdit eden patolojilerin hızlı ve doğru bir şekilde dışlanabilmesine olanak sağlamaktadır (11-13). Yüksek hassasiyete sahip bu gibi algoritmaların kullanılması, en çok yoğun acil servislerde radyologların geri dönüş sürelerindeki gecikmelere bağlı şekillenebilen zaman kayıplarının önüne geçilmesinde veya sınırlı radyoloji uzmanı destegine sahip kırsal bölgelerdeki acil servislerde özellikle yararlı olacaktır. Buna benzer diğer bir makine öğrenmesi modeli ile yapılan çalışmada ise radyografilerdeki el ve ayak bileği kırıkları gibi yaygın ortopedik yaralanmalari tanımlamak için kidemli ortopedik cerrahlarla karşılaşırılabılır düzeylerde bir performans elde edilmiştir (14). Bu gibi algoritmalar sayesinde, kırıkların güvenilir bir şekilde tanımlanmasıyla gereksiz konsültasyon ihtiyacı azalacak ve daha hızlı hasta müdahalesi sağlanabilecektir.

Sağlık alanında görüntülerin tanınmasındaki gelişmelerin, tıbbi görüntü analizinin birçok alanına doğrudan uygulanabileceği yapılan çalışmalar ile de gösterilmiştir. Derin öğrenme yöntemlerinin akciğer grafisinde pnömoniyi doğru bir şekilde tespit ettiği, beyin bilgisayarlı tomografisinde subdural hematomların 3D segmentasyonunu sağlayabildiği, serebral anevrizma rüptürü riskini değerlendirebildiği ve akut iskemik inme şüphesi olan hastaların BT görüntülerini inme konusundaki uzmanlar kadar doğru bir şekilde puanlayabildiği rapor edilmiştir (15-18). Derin öğrenme ile ilgili yapılan başka bir çalışmada ise beyin manyetik rezonans görüntülerine yapılan uygulamalar, psikozun ilk atağına sahip olan hastaları kontrollerden ayırt etmek ve ayrıca yine hastalarda yaşam boyu alkol tüketimini tahmin etmede kullanılmıştır (19, 20). Acil servis hizmetleri için derin öğrenme ile ilgili denemeler yapılmıştır. Travmaya odaklanmış karın ultrasonografisi (FAST-Focused Abdominal Sonography for Trauma) taramalarında abdominal serbest sıvayı saptamada yüksek düzeyde doğruluk göstermiştir ve ekokardiyogramda ejeksiyon fraksiyonunun otomatik olarak analizini de yapabilmştir (21, 22).

Acil serviste dikkat edilmesi gereken önemli başka bir konu da durumu kötüleşen hastaların erken bir şekilde tanımlanabilmesidir. Bunun için oluşturulmuş tıbbi rezerv indeksinde, yaklaşımakta olan kardiyovasküler bir unstabiliteti tahmin etmek amacıyla parmak ucu arteriyel kan basıncı verilerindeki dalga biçimindeki küçük değişiklikleri tespit edebilmeye yönelik çeşitli makine öğrenmesi yöntemleri kullanılmıştır (24). Bu durum özellikle de kliniği kötüleşebilecek travma hastalarının erken teşhis edilmesinde önemli kolaylık sağlayacaktır. Travmatik yaralanmalardan sonra gözlenen en önemli ölüm nedenlerinden birisi kanamadır. Sistolik kan basıncı dahil olmak üzere çeşitli standart ölçümler, bu durumu tıbbi rezerv indeksi mekanizmalar şekillenene kadar fizyolojik düzelmeye ait zayıf göstergelerdir. Tıbbi Rezerv İndeksinin, fizyolojik rezervi değerlendirme yeteneğine sahip olan yeni bir izleme teknolojisi olduğu yapılan çalışmalarla kanıtlanmıştır (25). Yine bahsedilen bu makine öğrenmesi ile yapılan başka bir çalışmada

ise telafi edici rezerv indeksi, istemli olarak meydana getirilen bir kanama sonucunda doğrusal bir şekilde azalma göstermiştir. Bu indeksin monitör ekranına eklenmesi sonucunda yaklaşımda olan unstabilitenin daha erken bir sürede tanımlanabilmesi sağlanmıştır (26, 27).

Erken teşhis ve tedavi ile birlikte önemli ölçüde iyileşme gösterebilen ve прогнозу iyiye giden durumlardan biri de sepsis tablosudur. Kalp hızı ve kan basıncı dinamiklerine uygulanan makine öğrenmesi sistemi ile sepsisi kliniğinin başlangıcından 4 saat öncesine kadar öngörebilmek mümkün olmuştur (28). Benzer şekilde makine öğrenmesi tabanlı bir sepsis tahmin algoritması olan InSight ile algoritmaya girilen verilerin eksik olmasına rağmen zamanla yaşamsal belirtilerden değişikliklere bağlı olarak algoritma sepsis ve ciddi düzeydeki sepsisi başlangıcından saatler öncesi bile tahmin edebilmiştir (29).

Acil servis hekimleri için oldukça önemli olan elektrokardiogram (EKG) analizine uygulanan bir derin öğrenme algoritmasıyla 15 farklı aritmi, sinüs ritmi ve parazit bulgusu alanındaki uzman kardiyologlardan bile daha yüksek bir doğrulukla tespit edilebilmiştir (30).

Acil servislerde kullanılan akıllı monitörlerin en önemli sorunlarından birisi yanlış olarak verdikleri alarmlardır. Bundan dolayı yanlış alarmları önlemek amacıyla kullanılan makine öğrenmesi ile yanlış alarmların %80'ini engellenebilirken, doğru verilen alarmların sadece %1'i algoritma tarafından engellenmiştir (31). Hastaların vitallerini takip etmede kullanılan izleme aparatlarının ya da monitörlerinin hasta ile herhangi bir teması olmadan sadece video görüntüsü kullanarak kalp atış hızını ve solunum hızını ölçümede makine öğrenmesi algoritmalarını kullanan yeni teknolojiler de geliştirilmiştir (32). Ayrıca makine öğrenmesi, benzer şekilde tek bir kol bandı kullanılarak manşonsuz olarak kan basıncını ölçme ve EKG kaydı kullanılarak kan basıncını doğru bir şekilde tahmin etmek için de kullanılmıştır (33, 34).

Yapay zekâ algoritmaları yine acil servislerde hastaların klinik sonlanımlarını tahmin etmede genel olarak mevcut klinik puanlama sistemlerinden artık daha iyi düzeyde performans gösterebilmektedir (35). Rajkomar ve arkadaşları, 200.000'den fazla hastanın tüm elektronik tıbbi kayıtlarından elde edilen ham verileri kullanarak geliştirdikleri algoritma ile daha yüksek ve başarılı bir oranla hastane içi mortaliteyi tahmin edebilmişlerdir (36). Makine öğrenmesi algoritmaları yaşamsal belirti ve ayrıca tıbbi kayıt verilerine de uygulanarak 72 saat içinde kardiyak arresti tahmin etmek üzere bir tür puanlama sistemi geliştirilmiştir. Benzer şekilde eksik veriler ve parazitler içeren tıbbi kayıtlar üzerinden eğitimi sağlanan makine öğrenmesi ile geliştirilen modeller de kardiyovasküler risk için kullanılan "TIMI" ve "GRACE" skorlamalarından daha iyi düzeyde performanslar sergilemişlerdir (37, 38). Liu ve arkadaşları kalp hızını 5 dakika boyunca 12 derivasyonlu EKG verisi üzerinden gözlemleyerek olumsuz kardiyovasküler sonuçları tahmin etmek üzere hayatı belirtiler ve verileri de içeren bir makine öğrenmesi modeli geliştirmiştirlerdir. Bu modelin invaziv araştırmalara gerek kalmadan TIMI skorlamasından daha iyi performans gösterdiği bulunmuştur. Model aynı zamanda ST elevasyonu olan miyokard enfarktüsünü takiben 30 günlük süreçteki mortaliteyi doğru bir şekilde tahmin etmek amacıyla da kullanılmıştır (39, 40). Molaei ve arkadaşları yine bir makine öğrenmesi algoritmasını pozitif BT bulgusuna sahip olması muhtemel olan travma hastalarını belirlemek amacıyla da geliştirmiştirlerdir. Algoritmalarını, yaygın olarak kullanılan Kanada kuralları ile karşılaştırmışlar ve algoritmalarının daha iyi bir performans

ortaya koymalarını tespit etmişlerdir. Ayrıca bu algoritmanın başarısı Travma Skoru-Yaralanma Şiddet Skorunu (TRISS) geride bırakarak travma hastalarında hayat kurtaran müdahale ihtiyacını tahmin edebilme yeteneğine de sahip olduğunu göstermiştir (41, 42).

Ülkemizde acil servislere acil olmayan vakaların da başvurularının oldukça fazla oranda artmış olmasından dolayı, gerçekten acil olan hastalara zamanında ve doğru müdahale edilmesi zorlaşmaktadır. Acil servisteki hastalar genellikle tanı veya tedavideki gecikmelerin kötü sonuçlara yol açabileceği zamana bağlı değişim gösterebilen kritik hastalık süreçlerine sahiptirler. Bu nedenlerle, acil servis iş akışlarını hedefleyen klinik karar desteği de zamanında gerçekleştirilmelidir. Yakin zamanda, bir ilaçın verilmesi, bir testin istenmesi veya tanı kodunun atanması gibi karar desteği başlatmak üzere kullanılan geleneksel yöntemler yerlerini yeni oluşturulacak olan yapay zekâ algoritmaları ve modellemelerine bırakacaktır.

Feng ve arkadaşları, 2019'da pandemiye neden olan ve halen daha onunla savaştığımız yeni koronavirüs enfeksiyonu COVID-19'un tüm sağlık sistemini ciddi şekilde etkilemesinden dolayı enfeksiyonun erken teşhisine yardımcı olmak amacıyla bir tanı modeli geliştirmiştirler. BT görüntülemesi yapılmadan, yalnızca klinik bilgilere dayanan bir makine öğrenmesi modeli ile enfeksiyon kliniklerine kabul edildiklerinde şüpheli olan COVID-19 hastalarının erken şekilde tanımlanabilmelerini %100 hatırlama puanına sahip bir performansla gerçekleştirebildiği gösterilmiştir. Bu geliştirdikleri yüksek performanslı ve doğrulanmış modeli de web sitesinden erişilebilen çevrimiçi bir triaj aracı olarak kullanıma sunmuştur (43).

Acil serviste, tıbbi kararları verirken birçok konuda belirsizlikler yaşanabilmektedir ve problemleri çözmede yapay zekâ algoritmaları kullanılabilir. Yapılan bir çalışmada akut karn ağrısı ile başvuran hastaların versiyon 4 acil durum şiddet indeksi olan ESI-4 skorunu tahmin etmede bir yapay zekâ algoritması uygulanmıştır. Çalışma sonucunda akut karn ağrısı olan hastaların triajında bu uygulanan yapay zekâ algoritmasının kabul edilebilir oranda doğruluk düzeyine sahip bir model olduğu gösterilmiştir (44).

Sonuç

Halen mevcut bulunun bazı sınırlılıklarına rağmen, mevcut yapay zekâ teknikleri ve algoritmaları ile çeşitli klinik alanlarda iyi düzeyde tanımlanmış sorunlar çözülebilmektedir. Bu tür sistemlerin geliştirilmesi ve kullanılması, özellikle acil servislerde hasta bakımını birçok açıdan iyileştirebilme potansiyeline sahiptir. Yakın gelecekte gelişen yapay zekâ teknolojileri ile sorunların çözümünün uygulamaya entegrasyonları ve yüksek kaliteli sağlık hizmetlerinin daha etkin, verimli ve doğru bir şekilde sunulması yoluyla hastalara, hekimlere, sağlık çalışanlarına ve ülke ekonomisine ciddi düzeyde fayda sağlayabileceğinin öngörümektedir ve bu alandaki çalışmaların artan şekilde desteklenmesi ülkemiz ve dünya adına ciddi önem arz etmektedir.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması veya finansal destek bildirmemişlerdir.

Finansman

Yok

Teşekkürler

Etki Onay

Yok

KAYNAKLAR

1. Jordan MI, Mitchell TM. Machine learning: Trends, perspectives, and prospects. *Science* 2015;80(349):255–60. <https://doi.org/10.1126/science.aaa8415>.
2. Ramesh A, Kambhampati C, Monson J, Drew P. Artificial intelligence in medicine. *Ann R Coll Surg Engl.* 2004;86(5):334–8.
3. Lynch S. Andrew Ng: why AI is the new electricity. Stanford News. 2017. [Cited 15 Mar 2018.] Available from URL: <https://news.stanford.edu/thedish/2017/03/14/andrew-ng-why-ai-is-the-new-electricity>
4. Obermeyer Z, Emanuel EJ. Predicting the future — big data, machine learning, and clinical medicine. *N Engl J Med* 2016;375:1216–9. <https://doi.org/10.1056/NEJMmp1606181>.
5. Senders JT, Arnaout O, Karhade AV, et al. Natural and artificial intelligence in neurosurgery: a systemic review. *Neurosurgery* 2017;0:1–12. <https://doi.org/10.1093/neurology/nyx384>.
6. Chen MC, Ball RL, Yang L, et al. Deep learning to classify radiology free-text reports. *Radiology* 2017;171115. <https://doi.org/10.1148/radiol.2017171115>.
7. Walton OB, Garoon RB, Weng CY, et al. Evaluation of automated teleretinal screening program for diabetic retinopathy. *JAMA Ophthalmol* 2016;134:204. <https://doi.org/10.1001/jamaophthalmol.2015.5083>.
8. Esteva A, Kuprel B, Novoa RA, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 2017;542:115–8. <https://doi.org/10.1038/nature21056>.
9. Liu N, Holcomb J, Wade C, Darrah M, Salinas J. Utility of vital signs, heart rate variability and complexity, and machine learning for identifying the need for lifesaving interventions in trauma patients. *Shock*. 2014;42(2):108–14.
10. Houthooft R, Ruyssinck J, van der Herten J, et al. Predictive modelling of survival and length of stay in critically ill patients using sequential organ failure scores. *Artif Intell Med.* 2015;63(3):191–207.
11. Prevedello LM, Little KJ, Qian S, White RD. Automated critical test findings identification and online notification system using artificial intelligence in imaging. *Radiology* 2017;0:1–9. <https://doi.org/10.1148/radiol.2017162664>.
12. Li YH, Zhang L, Hu QM, Li HW, Jia FC, Wu JH. Automatic subarachnoid space segmentation and hemorrhage detection in clinical head CT scans. *Int J Comput Assist Radiol Surg* 2012;7:507–16. <https://doi.org/10.1007/s11548-011-0664-3>.
13. Xiao F, Liao CC, Huang KC, Chiang IJ, Wong JM. Automated assessment of midline shift in head injury patients. *Clin Neurol Neurosurg* 2010;112:785–90. <https://doi.org/10.1016/j.clineuro.2010.06.020>.
14. Olczak J, Fahlberg N, Maki A, et al. Artificial intelligence for analyzing orthopedic trauma radiographs: deep learning algorithms—are they on par with humans for diagnosing fractures? *Acta Orthop* 2017;3674:1–6. <https://doi.org/10.1080/17453674.2017.1344459>.
15. Rajpurkar P, Irvin J, Zhu K, et al. CheXNet: radiologist-level pneumonia detection on chest X-rays with deep learning. *arXiv:171105225*. 2017. [Cited 21 Mar 2017.] Available from URL: <http://arxiv.org/abs/1711.05225>
16. Farzaneh N, Soroushmehr SMR, Williamson CA, et al. Automated subdural hematoma segmentation for traumatic brain injured (TBI) patients. *Conf Proc IEEE Eng Med Biol Soc*. 2017;2017:3069–72.
17. Liu J, Chen Y, Lan L, et al. Prediction of rupture risk in anterior communicating artery aneurysms with a feed-forward artificial neural network. *Eur Radiol*. 2018;28:3268–75.
18. Herweh C, Ringleb PA, Rauch G, et al. Performance of e-ASPECTS software in comparison to that of stroke physicians on assessing CT scans of acute ischemic stroke patients. *Int J Stroke* 2016; 11: 438–45.
19. Squarcina L, Perlini C, Peruzzo D, et al. The use of dynamic susceptibility contrast (DSC) MRI to automatically classify patients with first episode psychosis. *Schizophr Res.* 2015; 165: 38–44.
20. Guggenmos M, Scheel M, Sekutowicz M, et al. Decoding diagnosis and lifetime consumption in alcohol dependence from grey-matter pattern information. *Acta Psychiatr Scand.* 2018; 137: 252–62.
21. Sjogren AR, Leo MM, Feldman J, Gwin JT. Image segmentation and machine learning for detection of abdominal free fluid in focused assessment with sonography for trauma examinations: a pilot study. *J. Ultrasound Med.* 2016; 35:2501–9.
22. Knackstedt C, Bekkers SCAM, Schummers G, et al. Fully automated versus standard tracking of left ventricular ejection fraction and longitudinal strain. *J. Am. Coll. Cardiol.* 2015; 66: 1456–66.
23. Persson M, Fhager A, Trefna HD, et al. Microwave-based stroke diagnosis making global prehospital thrombolytic treatment possible. *I.E.E.E. Trans. Biomed. Eng.* 2014; 61: 2806–17.
24. Convertino VA, Grudic G, Mulligan J, Moulton S. Estimation of individual-specific progression to impending cardiovascular instability using arterial waveforms. *J. Appl. Physiol.* 2013; 115:1196–202.
25. Johnson MC, Alarhayem A, Convertino V, et al. Compensatory reserve index: performance of a novel monitoring technology to identify the bleeding trauma patient. *Shock*. 2018 Mar 1;49(3):295–300.
26. Convertino VA, Howard JT, Hinojosa-Laborde C, et al. Individual-specific, beat-to-beat trending of significant human blood loss: the compensatory reserve. *Shock* 2015; 44: 27–32.
27. Muniz GW, Wampler DA, Manifold CA, et al. Promoting early diagnosis of hemodynamic instability during simulated hemorrhage with the use of a real-time decision-assist algorithm. *J. Trauma Acute Care Surg.* 2013; 75: 184–9.
28. Shashikumar SP, Stanley MD, Sadiq I, et al. Early sepsis detection in critical care patients using multiscale blood pressure and heart rate dynamics. *J. Electrocardiol.* 2017; 50: 739–43.
29. Mao Q, Jay M, Hoffman JL, et al. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU. *BMJ Open* 2018; 8: e017833.
30. Rajpurkar P, Hannun AY, Haghpanahi M, Bourn C, Ng AY. Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv:170701836*. 2017. [Cited 21 Mar 2017.] Available from URL: <http://arxiv.org/abs/1707.01836>
31. Plesinger F, Klimes P, Halamek J, Jurak P. False alarms in intensive care unit monitors: detection of lifethreatening arrhythmias using elementary algebra, descriptive statistics and fuzzy logic. *Comput. Cardiol.* 2015; 42: 281–4.
32. Monkaresi H, Calvo RA, Yan H. A machine learning approach to improve contactless heart rate monitoring using a webcam. *IEEE J. Biomed. Heal. Informatics* 2014; 18: 1153–60.

33. Zhang Q, Zhou D, Zeng X. Highly wearable cuff-less blood pressure and heart rate monitoring with single-arm electrocardiogram and photoplethysmogram signals. *Biomed Eng.* Online 2017; 16: 1–20.
34. Simjanoska M, Gjoreski M, Gams M, Madevska Bogdanova A. Non-invasive blood pressure estimation from ECG using machine learning techniques. *Sensors (Basel)* 2018; 18: 1160.
35. Stewart J, Sprivulis P, Dwivedi G. Artificial intelligence and machine learning in emergency medicine. *Emergency Medicine Australasia*. 2018 Dec;30(6):870-4.
36. Rajkomar A, Oren E, Chen K et al. Scalable and accurate deep learning with electronic health records. *Npj Digital Medicine* 2018; 1: 18.
37. Levin S, Toerper M, Hamrock E et al. Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. *Ann. Emerg. Med.* 2018; 71: 565–74.
38. VanHouten JP, Starmer JM, Lorenzi NM, Maron DJ, Lasko TA. Machine learning for risk prediction of acute coronary syndrome. *AMIA Annu. Symp. Proc.* 2014; 2014: 1940–9.
39. Liu N, Lee MAB, Ho AFW et al. Risk stratification for prediction of adverse coronary events in emergency department chest pain patients with a machine learning score compared with the TIMI score. *Int. J. Cardiol.* 2014; 177: 1095–7.
40. Shouval R, Hadanny A, Shlomo N et al. Machine learning for prediction of 30-day mortality after ST elevation myocardial infarction: an acute coronary syndrome Israeli survey data mining study. *Int. J. Cardiol.* 2017; 246: 7–13.
41. Molaei S, Korley FK, Soroushmehr SMR et al. A machine learning based approach for identifying traumatic brain injury patients for whom a head CT scan can be avoided. *38th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* 2016: 2258–61.
42. Sefrioui I, Amadini R, Mauro J, Fallahi A, Gabbielli M. Survival prediction of trauma patients: a study on US National Trauma Data Bank. *Eur. J. Trauma Emerg. Surg.* 2017; 43: 805–22.
43. Feng C, Wang L, Chen X, et al. A novel artificial intelligence-assisted triage tool to aid in the diagnosis of suspected COVID-19 pneumonia cases in fever clinics. *Annals of Translational Medicine.* 2021 Feb;9(3).
44. Farahmand S, Shabestari O, Pakrah M, et al. Artificial intelligence-based triage for patients with acute abdominal pain in emergency department; a diagnostic accuracy study. *Advanced journal of emergency medicine.* 2017;1(1).