



Will Machine Learning Take a Leading Role in Emergency Medicine Applications?

Acil Tıp Uygulamalarında Makine Öğrenimleri Başrolü Alır mı?

Savaş Sezik*

Ödemiş State Hospital, Department of Emergency Medicine, İzmir, Türkiye

Sorumlu Yazar | Correspondence Author

Savaş Sezik

savassezik@gmail.com

Address for Correspondence: Ödemiş State Hospital, Department of Emergency Medicine, Zafer, Ortac Sk. No:10, 35750 Ödemiş, İzmir, Türkiye

Makale Bilgisi | Article Information

Makale Türü | Article Type: Derleme | Review

Doi: <https://doi.org/10.52827/hititmedj.1467697>

Geliş Tarihi | Received: 12.04.2024

Kabul Tarihi | Accepted: 09.08.2024

Yayın Tarihi | Published: 25.02.2025

Atıf | Cite As

Sezik S. Will Machine Learning Take a Leading Role in Emergency Medicine Applications? Hitit Medical Journal 2025;7(1):118-123. <https://doi.org/10.52827/hititmedj.1467697>

Hakem Değerlendirmesi: Alan editörü tarafından atanan en az iki farklı kurumda çalışan bağımsız hakemler tarafından değerlendirilmiştir.

Etik Beyanı: Makale Derleme türünde olduğundan etik kurul onayına gerek yoktur.

İntihal Kontrolleri: Evet (iThenticate)

Çıkar Çatışması: Yazarlar çalışma ile ilgili çıkar çatışması beyan etmemiştir.

Şikayetler: hmj@hitit.edu.tr

Katkı Beyanı: Fikir/Hipotez SS Tasarım SS Veri Toplama/Veri İşleme SS Veri Analizi SS Makalenin Hazırlanması SS.

Hasta Onamı: Makale Derleme türünde olduğundan hasta onamına gerek yoktur.

Finansal Destek: Bu çalışma ile ilgili herhangi bir finansal kaynaktan yararlanılmamıştır.

Telif Hakkı & Lisans: Dergi ile yayın yapan yazarlar, CC BY-NC 4.0 kapsamında lisanslanan çalışmalarının telif hakkını elinde tutar.

Peer Review: Evaluated by independent reviewers working in the at least two different institutions appointed by the field editor.

Ethical Statement: Ethical committee approval is not required.

Plagiarism Check: Yes (iThenticate)

Conflict of Interest: The authors declared that, there are no conflicts of interest.

Complaints: hmj@hitit.edu.tr

Authorship Contribution: Idea/Hypothesis: SS Design: SS Data Collection/Data Processing: SS Data Analysis: SS Manuscript Preparation: SS.

Informed Consent: Our University Clinical Research Ethics Committee has confirmed that no consent for publication from patients is required.

Financial Disclosure: There are no financial funds for this article.

Copyright & License: Authors publishing with the journal retain the copyright of their work licensed under CC BY-NC 4.0.

Acil Tıp Uygulamalarında Makine Öğrenimleri Başrolü Alır mı?

ABSTRACT

The main problems in the workflows of emergency services can be summarized as over-crowding, unnecessary usage trends and long waiting times. Emergency services experienced a breaking point during the pandemic, and new approaches regarding to management have come to the agenda. Health care providers around the world are looking to artificial intelligence as the solution to these challenges. applications into emergency department business processes. In the future, artificial intelligence-based machine learning models will be integrated to the clinical decision making support systems to reduce the workload of physicians, and also play an auxiliary role in the emergency services. In this article, we will discuss on the basis of the reasons that led to the combination of machine learning to summarize the current status of modeling in emergency services. It is brought to the fore that machine learning models enhance clinicians' decision-making abilities, reduce diagnostic errors, and alleviate cognitive load.

Keywords: Artificial Intelligent, ChatGPT, emergency department, machine-learning models.

ÖZET

Acil servislerde iş akışlarındaki temel problemler; yoğunluk, gereksiz kullanım eğilimleri ve uzun bekleme süreleri olarak özetlenebilir. Covid-19 pandemisi sırasında kırılma noktasını yaşayan acil servis yönetiminde yeni yaklaşımlar gündeme gelmiştir. Sağlık hizmeti sağlayıcıları, dünya çapında bu zorlukların çözümü olarak, yapay zekâ uygulamalarını acil servis iş süreçlerine dâhil etmeye başlamışlardır. Yapay zeka tabanlı makine öğrenimi modelleri, gelecekte klinik karar destek sistemlerine entegre edilerek hekimlerin iş yükünü azaltmalarının yanında acil servis işleyişleri için de yardımcı rol oynayacaklar gibi görünmektedir. Biz bu yazımızda, acil serviste makine öğrenimi birlikteliğine götüren nedenler temelinde modellemelerin acil servis hizmetlerindeki güncel durumu özetlemeye çalıştık. Makine öğrenimi modellerinin klinisyenlerin karar verme yetilerini geliştirdiği, tanısız hataları ve bilişsel yüklenmeyi azalttığı görüşleri öne çıkmaktadır.

Anahtar Sözcükler: Acil servis, ChatGPT, makine öğrenim modelleri, yapay zeka.

Giriş

Basit bir tanımla yapay zekâ, bilgisayarların görevleri tamamlamasına veya geleneksel anlamda tipik olarak insan zekâsı gerektirecek bilgi üretmesine odaklanan bilgisayar bilimi alanıdır. Yapay zekâ kapsamında makine öğrenimi (MÖ) ve derin öğrenme alanları bulunmaktadır. Teorik olarak MÖ, farklı sorun türlerinin çeşitli algoritmalar ile çözümlenmesini sağlarken yaşam kalitesini arttıran pratik çözümler üretir (1). Veri akışı sürekliliğinde, otomatik 'iyileştirme' veya "öğrenme" yeteneğine sahiptir. MÖ ve derin öğrenme ile büyük miktarlarda veri analiz edilir, özerk olarak varsayımlar üretilir. Klinik sonuçların daha doğru tahmin edilmesi sağlanır (2).

Acil Servis ve Makine Öğrenimi Birlikteliğine Götüren Nedenler

Mükemmel bir dünyada dahi, acil durumlarla başa çıkmaya hazırlıklı olmak çok önemlidir. Acil durumlar; herhangi bir zamanda, herhangi bir uyarı olmaksızın, en son teknolojiler kullanılıyor olsa bile ortaya çıkabilir. Acil durum yönetimi, çok sayıda aracı içeren senkronize bir faaliyettir (3). Dünya genelinde acil servis başvurularında nüfus artış hızından daha fazla bir artış olduğu gözlenmektedir (4). Acil olmayan nedenler ile başvuru, tekrar eden başvurular, yatış süresinde uzama, personel eksikliği gibi nedenler acil servislerde yoğunluğa neden olmaktadır (5). Bu yoğunluğun sonucu olarak mortalite, komplikasyon, tedavi bırakma, acil serviste kalış süresi, memnuniyetsizlik oranlarında artış gözlenmektedir. Acil servislerdeki iş akışının iyileştirilmesinin yanı sıra acil servis profesyonellerinin yeni yaklaşımlar ile bu iş akışlarını daha sistematik olarak düzenlemeleri yapay zekâ uygulamalarının gündeme gelmesini hızlandırmıştır (6). Bilgi teknolojisi çağında, sağlık alanında MÖ hasta süreçlerinin öngörüsü, elektronik sağlık kaydının otomatik olarak çıkarılması, dijital görüntülerin bütünleştirilmesi ve fizyolojik verilerin sürekli izlenmesi yoluyla tahmin modellerinin güncellenmesi gibi avantajlar sunmaktadır (7). MÖ modellerinin oluşturulması, acil serviste özellikle bazı durumlarda (sepsis, planlanmamış yoğun bakım ünitesine yatışlar, planlanmamış rekürren başvurular, vb.) öngörünün gelişmesine destek olmaktadır (8). Ayrıca, tahmin ediciler arasındaki yüksek dereceli, doğrusal olmayan etkileşimler ile daha kararlı tahminler yapılabilme avantajı da ortaya çıkmaktadır (9).

Acil Servis Hizmetlerinde Makine Öğrenimi Uygulama Alanları

Acil servislerde kaynak planlaması, iş yükünün tahmini ve yoğunluk yönetimi konularında matematiksel modelleme yöntemleri kullanılmaktadır (10). Hastaları taramak, katmanlaştırmak ve özelleşmiş tanımlar koymak için MÖ temelli tanısal karar destek uygulamaları, tanısal modelleme sistemleri kullanılmaktadır. Bu araçların kullanılması yüksek düzeyde otomatikleştirilmiş sonuçlar için umut verici bir doğruluk göstermekte ve uygulanan model iyileştirmeye giden yolu göstermektedir (11). Yapay zekâ uygulamaları; tanısal görüntülemenin yorumlanmasında, hasta sonuçlarının tahmin edilmesinde ve hastanın yaşamsal belirtilerinin izlenmesinde (nabız hızı, kan basıncı, sıcaklık ve solunum takibi) umut verici sonuçlar ortaya koymuştur (12). MÖ modelleri, semptomları doğru bir şekilde değerlendirip sınıflandırarak, acil servise başvuran hastanın yaşam ile ölüm arasındaki çizgide aciliyet ve tedavi önceliğinin belirlenmesinde ilk değerlendirme olan acil durum seviyelerinin (triyaj) tahmin edilmesinde kullanılmaktadır (13). Acil servis triyajında yüksek riskli hastaları daha stabil hastalardan doğru bir şekilde ayırt etmek ve kesin kaynakları etkin bir şekilde kullanmak hedeflenmektedir (14). Bora ve ark. e-triyajda dört farklı makine öğrenmesi (Support Vector Machine (SVM), Kth Nearest Neighbor (KNN), Decision Trees, Random Forest) algoritmalarını değerlendirdikleri çalışmalarında Random Forest yaklaşımının daha iyi performans gösterdiğini rapor etmişlerdir (15). Goto ve ark. astım ve kronik obstrüktif akciğer hastalığı (KOAH) hastalarının triyajını kolaylaştırmak ve acil servis eğilimlerini (yoğun bakım, hastaneye yatış) tahmin etmek için dört MÖ yaklaşımları kullandıkları çalışmalarında en iyi performansın yoğun bakım için Boosting, hastaneye yatış için Random Forest yaklaşımlarının sağladığını belirtmişlerdir (16). Raite ve ark. geleneksel yaklaşımla (Emergency Severity Index (ESI)) karşılaştırıldığında, MÖ modellerinin (Lasso regression, random forest, gradient boosted decision tree, deep neural network) kritik bakım ve hastaneye yatış sonuçlarını tahmin etmek için üstün bir performans gösterdiğini rapor etmişlerdir (17).

Makine Öğrenimi Modelleme Yöntemleri

Başlıca MÖ yaklaşımları denetimli öğrenme, denetimsiz öğrenme ve yarı denetimli öğrenme

kategorisine girer. Denetimli öğrenme algoritmaları, eğitim verileri olarak bilinen tarihsel olarak etiketlenmiş bir veri kümesini kullanarak matematiksel bir model oluşturur. Ancak denetimsiz öğrenmede, veri kümesinin her kaydı için etiket mevcut değildir. Eğitim verileri ve denetimli öğrenme algoritmaları kullanılarak bir model geliştirilir. Daha sonra çıktı elde etmek amacıyla test verileri üzerinde girdiye dayalı tahmin test edilir (18). Denetimli öğrenme algoritmaları sınıflandırma ve regresyonu içerir (19). Bu alandaki en önemli algoritmalarından bazıları; lojistik regresyon, destek vektör makineleri (support vector machines - SVM), naive Bayes algoritması, karar ağaçları (Decision Trees), rastgele orman (Random Forest), gradyan artırma ve derin öğrenmedir. Elektronik sağlık kayıtlarında büyük miktarda verinin bulunması, tahmine dayalı modelleme için büyük ve karmaşık veri setlerinin kullanılmasına olanak sağlar. Tıbbi verilerin işlenmesinde popüler bir yaklaşım olan 'Lojistik Regresyon' algoritması ile ilk tahminleme için iyi sonuçlar elde edilir (20). Ancak bağımsız değişkenlerin gözlemlerden daha fazla olması durumunda lojistik regresyon yönteminin kullanımı mümkün olmayacaktır (21). Bu sorunu çözmek için etkili ve verimli değişken seçiminin yapılması gerekmektedir. Değişkenleri, hesaplanan önemlerine göre sıralamak için daha düşük tahmin hatasına sahip Random Forest kullanılabilir (22).

Logistic Regresyon: Verilerin eğrisine bir çizgi yerleştirerek değişkenler arasındaki ilişkilerin doğrusal bir modelini keşfeden bir MÖ algoritmasıdır. Sınıflandırma için de uygulanabilir.

Lasso Düzenlemeli Logistic Regresyon (Lasso Regresyonu): Regresyon katsayılarını sıfıra doğru küçülten, böylece önemli belirleyicileri etkin bir şekilde seçen ve modelin yorumlanabilirliğini artıran modellerden biridir (23).

Support Vector Machine (SVM): Yönetimi ve kullanımı kolay sınıflandırma algoritmasıdır. Bu algoritmada, bir veri ögesi olan her nokta 'n' boyutlu düzlem olarak bilinen uzayda boyutlu olarak çizilir. 'N' verinin özellik sayısını temsil eder. Sınıflandırma, farklı düzlemlerde bulunan veri kümesi noktalarının oluşturduğu sınıflardaki farklılaşmaya dayalı olarak yapılır. MÖ'nde tercih edilen ve kullanılan bu yöntem sıklıkla denetimli öğrenme problemlerinin çözümünde etiketlenmemiş veri miktarının fazla olduğu durumlarda verilerin gerçek zamanlı etiketlenmesi için

sınıflandırılmasında tercih edilir. Basit bir doğrusal sınıflandırma olarak düşünülebilmesi için düşük boyutlu uzaydaki doğrusal olmayan problemin yüksek boyutlu bir uzayla eşleştirildiği yöntemdir. Küçük örneklem yönetimi için uygundur (24). Veriler için en iyi veri sınıflandırıcısını ayırt etmek için kullanılan bir algoritmadır. SVM çok iyi bir genelleme performansı elde edebilir.

Deep neural network model (Derin sinir ağı modeli), çoklu işlem katmanlarından oluşur. Sonuçlar, ara gizli birimler tarafından modellenir ve her gizli birim, doğrusal olmayan işlemlere dönüştürülen yordayıcıların doğrusal kombinasyonundan oluşur (9). Bir hücre ağının üretildiği ve hücreler arasındaki bağlantıların, elde edilen ağın eğitim verilerinin yapısını öğrenebileceği şekilde ayarlandığı yapay sinir ağı (ANN) adlı başka bir MÖ yöntemleri sınıfının bir parçasıdır. Genellikle, derin öğrenme yöntemindeki ağdaki katman sayısı, sıradan bir ANN'den çok daha yüksektir. Derin öğrenme, giriş verilerinden daha üst düzeyde çıkarılan özellikler içerir.

Kth Nearest Neighbor (KNN): KNN algoritması, sınıflandırılacak yeni bireyin yakınlığının önceki bireylerin k katı ile kontrol edildiği bir algoritmadır. Sınıflandırma sırasında test örnekleri, eğitim örnekleri kullanılarak birbirleriyle karşılaştırılır. Yakınlık aralığının değerlendirilmesinde Öklid mesafesi kullanılır. Tahminler, komşu örneklerin çoğunluk oylamasına dayanmaktadır. Yüksek k değerlerine uyma eğiliminde olduğu için dikkatli olunmalıdır (25).

Decision Trees (Karar Ağaçları): Karar ağaçları sadece kararları göstermekle kalmaz, aynı zamanda kararların açıklamalarını da içerir. Karar ağacını oluşturan eğitim süreci tümevarımsaldır. Bir dizi eğitim nesnesinden bir karar ağacı oluşturma prosedürüne 'tree induction' denir. Bu yöntemi, kendini keşfetmenin en yaygın yöntemlerinden biridir. Sınıflandırma veya tahmin amacıyla kullanılacak ağaç benzeri kalıpları keşfetmeye hizmet eder.

Karar ağaçları, bilgi keşfi sırasında çeşitli testler yaparak hedefi tahmin etmek için en iyi sırayı bulmaya çalışır. Her test karar ağacında dallar oluşturur ve bu dallar başka testlerin yapılmasına neden olur. Bu işlem, test işlemi bir yaprak düğümünde bitene kadar devam eder. Kökten hedef yaprağa giden yola, hedefi sınıflandıran "kural" denir. Kurallar "eğer öyleyse" modelini yansıtır (26). Karar ağacı, ağaç benzeri

yapıları kullanarak verileri eşlemek, çıktıya alınacak kararları sınıflar veya sınırlar olarak sınıflandırmak için kullanılan başka bir algoritmadır.

Gradyan artırılmış karar ağacı: Önceki modellerin hatalarını ve artıklarını tahmin eden yeni ağaç modelleri oluşturan bir topluluk yöntemidir. Bu model, yeni modelleri eklerken, bir kayıp işlevini en aza indirmek için gradyan alçalma algoritması kullanır (27).

Random Forest: Denetimli bir öğrenme algoritması olan rastgele orman algoritması, sınıflandırma ve regresyon görevlerinde kullanılır. Rastgele orman algoritması, birden fazla karar ağacı oluşturur ve daha doğru ve istikrarlı bir tahmin elde etmek için bunları birleştirir. Birkaç rastgele karar ağacını birleştiren ve tahminlerinin ortalamasını alan yaklaşım, değişken sayısının gözlem sayısından çok daha büyük olduğu ortamlarda daha iyi performans gösterir (28).

Yöntem bankacılık, ticaret, sağlık gibi birçok alanda kullanılmaktadır. Sağlık alanında, tıpta doğru bileşen kombinasyonunu belirlemek, hastalıkları belirlemek ve hastanın tıbbi kayıtlarını kullanarak hastanın tıbbi geçmişini analiz etmek için kullanılır. Rastgele orman sınıflandırıcısı, her sınıflandırıcının, giriş vektöründen bağımsız olarak örneklenen rastgele bir vektör kullanılarak oluşturulduğu ve her ağacın bir giriş vektörünü sınıflandırmak için en popüler sınıfa tek birim oy verdiği ağaç sınıflandırıcılarının bir kombinasyonundan oluşur. Bir karar ağacının tasarımı, bir nitelik seçim ölçüsünün ve bir budama yönteminin seçilmesini gerektirir. Karar ağacı çıkarımı için kullanılan öz niteliklerin seçiminde birçok yaklaşım vardır ve çoğu yaklaşım, özneliğe doğrudan bir kalite ölçüsü atar. Karar ağacı indüksiyonunda en sık kullanılan nitelik seçim ölçüleri Information Gain Ratio (29) ve Gini Endeksi (30).

Acil Servis Uygulamalarında Makine Öğreniminin Geleceği ve Uygulamada Olası Engeller

MÖ modelleri, bilgiyi kodlayan sabit kurallara dayalı kararların alındığı geleneksel modeller ile ulaşılması zor olan, ölçeklenebilirliği gerçekleştirirler. MÖ yaklaşımlarının klinik karar verme yeteneklerini daha da ilerletmek için vazgeçilmez yeni nesil yardımcı teknoloji olacaktır (31). Yeterli klinik kanıt ve uygun bir düzenleyici çerçeve olduğu varsayıldığında, yapay zekânın etkin bir şekilde kullanılmasında dijital teknolojiye geçiş temelli olası engeller olabileceği de göz önünde bulundurulmalıdır. Elektronik tıbbi

kayıtların doğru, tam zamanlı ve eksiksiz alınması gerekli olup bu kayıtların mevcut klinik iş akışına entegrasyonunun sağlanması önemlidir.

Yapay Zekâ ve Etik Sorunsalı

İnsan gibi düşünüp yorumlayan, muhakeme eden ve sonuçlar çıkaran yapay zeka uygulamalarının tabii ki etik sorunları da vardır. Belki de bu sorunlar yapay zeka uygulamalarını bir müddet daha güncel hayatımıza girmekten uzak tutacaktır. Bunların en başında bu kadar verinin bulunduğu hasta kayıtlarının istenildiği zaman ve miktarda sağlık personeline görülüyor olması hasta mahremiyeti açısından çok ciddi bir sorundur. Anayasal güvence altında olan sağlık hakkının bu uygulamaları kullanmayan kişilerce eşitsizlik olarak kabul edilebilecek olması, sağlık personeli ve bireylerin bu uygulamalara uyum sağlayamamasının getireceği karmaşık durumda sorunlardan bazılarıdır. Belki de en ciddi sorun bu uygulamalardan dolayı ortaya çıkabilecek zararların muhatabı kim olacak; Uygulayan sağlık profesyonellerimi yoksa üretici şirketler mi?

Sonuç

Acil servis verileri kullanılarak oluşturulan MÖ modellemelerine talep artmaktadır. Bu modellemeler klinisyenlerin, zamanında ve doğru klinik bakım ile optimal kaynak kullanımı konularındaki karar verme yetilerini geliştirirler, tanısal hataları ve bilişsel yüklenmeyi azaltırlar. Yapay zekâ tabanlı tahmin uygulamasının iyi olması, klinisyenlerin MÖ algoritmasının doğruluğuna güvenebilmesinin anahtarıdır (32). Sağlık alanında yapay zeka konusunda çalışanların, denetimsiz modellerden daha çok yorumlanabilir modeller geliştirmesi, yarı denetimli MÖ modellemesi oluşturması, bakım standardı veya klinik kararları karşılaştıran çalışmalar yapması beklenmektedir. Yakın gelecekte, bir zamanlar sağlık çalışanları tarafından yürütülen görevleri daha fazla yapay zekânın üstlendiği ve insan beyni ile yapay zekâ uyumunun sağlandığı görülebilecektir.

Kaynaklar

1. Alzubi J, Nayyar A, Kumar A. Machine learning from theory to algorithms: an overview. J. Phys. Conf. Ser.; NCCI 2018, 1142012012
2. Grant K, McParland A, Mehda S, Acckery AD. Artificial intelligent in emergency medicine: surmountable barriers

- with revolutionary potential. *Ann Emerg Med* 2020;75:721-726.
3. Kalhori SRN. Towards the application of machine learning in emergency informatics. *Stud Health Technol Inform* 2022;291:3-16
 4. Hooker EA, Mallow PJ, Oglesby MM. Characteristics and trends of emergency department visits in the United States (2010-2014). *J Emerg Med* 2019;56:344-351.
 5. Hoot NR, Aronsky D. Systematic review of emergency department crowding: causes, effects, and solutions. *Ann Emerg Med* 2008;52:126-136.
 6. Richardson DB. Increase in patient mortality at 10 days associated with emergency department overcrowding. *Med J Aust* 2006;184:213-216.
 7. Priesol AJ, Cao M, Brodley CE, Lewis RF. Clinical vestibular test ingassed with machine-learning algorithms. *JAMA Otolaryngol-Head Neck Surg.* 2015; 141:364-372.
 8. Taylor RA, PareJR, Venkatesh AK, et al. Prediction of in-hospital mortality in emergency department patients with sepsis: a local big data-driven, machine learning approach. *Acad Emerg Med Off J Soc Acad Emerg Med.* 2016;23:269-278.
 9. Kuhn M, Johnson K. *Applied predictive modeling.* NewYork:Springer Verlag; 2013.
 10. Sun Y, Heng BH, Seow YT, et al. Forecasting daily attendances at an emergency department to aid resource planning. *BMC Emerg Med* 2009;9:1
 11. Haug PJ, Ferraro JP, Holmen J, et al. An ontology-driven, diagnostic modeling system. *J Am Med Inform Assoc* 2013;20:e102-110.
 12. Ramesh AN, Kambhampati C, Monson JRT, et al. Artificial intelligence in medicine. *Ann R Coll Surg Engl.* 2004;86:334-338.
 13. 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.* 2017;71:565-574.
 14. Mistry B, Stewart DeRamirez S, Kelen G, et al. Accuracy and reliability of emergency department triage using the Emergency Severity Index: An International Multicenter Assessment. *Ann EmergMed.* 2018;71:581-587.
 15. Bora S, Kantarcı A, Erdoğan A, et al. Machine learning for E-trigae. *International Journal of Multidisciplinary Studies and Innovative Technologies* 2022;6:86-90.
 16. Goto T, Camargo CA Jr, Faridi MK, et al. Machine learning approaches for predicting disposition of asthma and COPD exacerbations in the ED. *Am J Emerg Med* 2018;36:1650-1654
 17. Raita Y, Goto T, Faridi MK, Brown DFM, Camargo CA Jr, Hasegawa K. Emergency department tirage prediction of clinical outcomes using machine learning models. *Crit Care.* 2019;23:64.
 18. Shafaf N, Malek H. "Applications of machine learning approaches in emergency medicine; a review article," *Archives of academic emergency medicine*, vol. 7, no. 1, 2019.
 19. Dwarakanath L, Kamsin A, Rasheed RA, Anandhan A, Shuib L. Automated Machine Learning Approaches for Emergency Response and Coordination via Social Media in the Aftermath of a Disaster: A Review. *IEEE Access.* 2021;9:68917-68931.
 20. Zabor EC, Reddy CA, Tendulkar RD, Patil S. Logistic regression in clinical studies. *Int J Radiat Oncol Biol Phys.* 2022;112:271-277.
 21. Johnson KW, Torres Soto J, Glicksberg BS, et al. Artificial Intelligence in Cardiology. *J Am Coll Cardiol* 2018;71:2668-2679.
 22. Fernandez-Delgado M, Cernadas E, Barro S, Amorim D. Do we need hundreds of classifiers to solve real world classification problems? *J. Mach. Learn. Res.* 2014;15:3133-3181.
 23. James G, Witten D, Hastie T, Tibshirani R. *An introduction to statistical learning: with applications in R.*NewYork:Springer-Verlag;2013.
 24. Vapnik V. *The Nature of Statistical Learning Theory.* New York:Springer-Verlag, 2000.
 25. Hastie T, Tibshirani R, Friedman JH, *The elements of statistical learning: data mining, inference, and prediction,* New York Springer, 2009.
 26. Bounsaythip C, Rinta-Runsala E. 2001. "Overview of data mining for customer behavior modeling", *VTT Information Tech. Rep.*, 2001;1:1-53.
 27. Natekin A, Knoll A. Gradient boosting machines, a tutorial. *Front Neurorobot.*2013.
 28. Biau G, Scornet E, A random forest guided tour, *Test,* 2016;25:197-227.
 29. Quinlan JR , *C4.5 Programs for Machine Learning,* USA, Morgan Kauffman, 1993
 30. Breiman L, "Random Forests", *Machine Learning,* 2001;45:5-32.
 31. Obermeyer Z, Emanuel EJ. Predicting the future- bigdata, machine learning, and clinical medicine. *N Engl J Med.*2016;375:1216-1219.
 32. Vantu A, Vasilescu A, Baicoianu A. Medical emergency department tirage data processing using a machine-learning solution. *Heliyon* 2023;9:e18402.