


Yapay Zeka Nedir?

Yapay zeka (AI), ortamdan algı almak ve algoritmalar, buluşsal yöntemler, desen eşleştirmeleri, kurallar, derin öğrenme ve bilişsel hesaplamayı kullanarak eylemler gerçekleştirmek gibi normalde insan zekası gerektiren görevleri gerçekleştirebilen bir bilgisayar sistemidir. Bir grup öncü, bu terimi ilk kez 1956'da ABD'nin New Hampshire kentindeki Dartmouth College'da icat etti. 1958'de Rosenblatt [9] mevcut sinir ağlarının ilk öncüsünü geliştirdi: Perceptron, ikili sınıflandırıcıların denetimli öğrenimi için bir “beyin modeli”. 1986'da Rymelhart ve ark. [10], herhangi bir fonksiyonu öğrenebilen nöron benzeri birimlerden oluşan ağlar için yeni bir öğrenme prosedürü olan geri yayılımı tanımladı. 90'lı ve 90'lı ve 2000'li yıllarda büyük ilerleme kaydedilmesine rağmen, ancak 2012'de Krizhevsky ve meslektaşları, ağ eğitimi hızlandırmak için GPU'ları (grafik işleme birimleri [*graphics processing units*]) kullanarak nesneleri sınıflandırmak için derin evrimsimli sinir ağıyla ImageNet ILSVRC yarışmasını kazandığında, araştırma faaliyetlerinde bir patlama yaşandı. sinir ağı alanında gerçekleşmeye başladı [11, 12]. Yapay zeka tekniklerinin, özellikle de ML ve DL alt alanlarındaki sürekli gelişimi, kaliteli sağlık hizmeti sağlamak için yeni entegre, güvenilir ve etkili yöntemler yaratma konusunda klinisyenlerin dikkatini hızla çekmiştir.

Kardiyovasküler tıpta yapay zeka söz konusu olduğunda görüntüleme ilginin ve araştırmanın odak noktasıdır.

Yapay Zeka (YZ), makinelerle akıl yürütme ve problem çözme gibi bilişsel f işlevleri gerçekleştirme yeteneği veren matematiksel algoritmaların kullanımını ifade eden genel bir terimdir(bakınız aşağıdaki figür).



- Ekokardiyografide ML modellerini kullanmanın avantajları, operatörler arası ve operatör içi değişkenliğin azaltılmasının yanı sıra, insan gözüyle tespit edilemeyecek kadar incelikli olabilecek ek öngörücü bilgilerin sağlanmasında yatmaktadır [13-15]
- AI tekniklerinin bir başka ilginç potansiyel uygulaması, KAH şüphesi olan hastalar için kardiyak BT'de olabilir. Bu rahatsızlıklardan muzdarip hastalar için, kardiyak bilgisayarlı tomografi(BT) ve makine öğrenme (*ML, machine learning*) algoritmaları arasındaki ilişki, klinik uygulamada invazif olmayan yaklaşımlar alma ve aterosklerotik plak karakterizasyonunun ötesinde fonksiyonel bilgileri tespit etme potansiyelini göstermiştir [16-18].
-
- Tanısal görüntülemenin yanı sıra, ML'nin kardiyolojideki bir diğer ilginç uygulaması, elektrokardiyogramlardaki anormalliklerin otomatik olarak tespit edilmesi olabilir.

Makine öğrenme. Makine öğrenimi (ML [*Machine learning*]) - karmaşık bilgi işlem ve istatistiksel algoritmaların kullanımı yoluyla bilgisayarlara geniş veri kümelerini hızlı, doğru ve verimli bir şekilde analiz etmeyi "öğretmeyi" amaçlayan yapay zekanın bir alt alanıdır [13].

Bu algoritmalar, halihazırda "öğrendikleri" mevcut verilerle eşleşen yeni veriler üzerindeki kalıpları belirleyebilir ve bunlara dayanarak tahminlerde bulunabilir [19].

ML'de, bir x girişi ve bir y çıkışı, tahmin modeli olarak adlandırılan $y = f(x)$ fonksiyonel ilişkisini takip eder [19].

ML, tahmine dayalı modelin öğrenme ve veri toplama şekline bağlı olarak üç gruba ayrılabilir [20-24].

- (1) Denetimli öğrenme (ör. lojistik regresyon, SVM ve sinir ağları): Genellikle gelecekteki olayları tahmin eden veya sınıflandıran veya sonuçla en alakalı değişkenleri bulan modeller geliştirmek için kullanılan, insan etiketli veri kümelerini kullanır. Hem x hem de y biliniyor ve öngörüye dayalı model düzeliyor ve veri eğitiminden yararlanıyor.
- (2) Denetimsiz öğrenme (örneğin küme analizi): yazılım, eğitim setinin önceden sınıflandırılmasına gerek kalmadan veri setlerindeki gizli yapıları bulma yeteneğine sahiptir (yalnızca x bilinir). Bu, veriler içindeki yeni ilişkileri tanımlama potansiyeline sahiptir.
- (3) Takviyeli öğrenme (*Forcement learning*): Olumlu ve olumsuz takviyelerin öngörücü modelin düzeltilmesine/geliştirilmesine katkıda bulunduğu bir ortamla etkileşimlere dayanan ödüle dayalı öğrenme (genellikle oyun ve robotik uygulamalarda kullanılır). Makinenin yalnızca öğrenmeyi geliştirmekle kalmayıp aynı zamanda sensörler, kameralar ve GPS gibi çevredeki ortamın özelliklerini de anlayabilen sistem ve araçlarla donatılmasını gerektirir.

Derin öğrenme- Derin öğrenme (DL), sinir ağlarını kullanan ve veri koleksiyonlarından anlamlı desenler çıkarabilen otomatik algoritmalarla karakterize edilen denetimli bir makine öğrenimi tekniğidir [4]. Çoklu soyutlama düzeylerine sahip verilerden karmaşık hiyerarşik temsilleri öğrenerek insan beyninin karmaşıklığını taklit eder [4, 25]. Programcı, bilinen verileri, tamamen yeni verilerle karşılaşıldığında bile algoritmaların doğru yanıt vermesini

sağlayacak şekilde makineye girer. Sinir ağı deneyim yoluyla öğrenir, verileri okur, hiyerarşik mimariler oluşturur ve gelişmiş giriş-çıkış seviyeleri sağlar. Girdi-çıkış sonuç değişkenleri arasındaki karmaşık doğrusal olmayan ilişkileri yakalayabilir. Sonuçların ortalama hatası ve tahminleri, girdi ve sonuç verilerinin ağırlıklarının tahmin edilmesiyle en aza indirilebilir [3].

Hekimler bilgi, deneyim ve kültürel geçmişlerine dayanarak teşhis koyarlar. Derin öğrenme bu noktada çok başarılı olabilir, özellikle uzman olmayan doktorlar için tıbbi bilgiyi genişletip düzeltebilir/geliştirebilir. DL, daha fazla gizli katman kullanarak verilerdeki klasik sinir ağlarına göre daha karmaşık doğrusal olmayan modelleri keşfedebilir. Bu nedenle, özellikle görüntüleme analiz alanı için veri hacminin ve karmaşıklığının artması nedeniyle DL'nin tıbbi araştırma alanında uygulanması son zamanlarda popüler hale gelmiştir [3, 26].

DL aynı zamanda Facebook'un görüntü tanıma programında, Apple'ın Siri'sinde ve Amazon'un Alexa'sında konuşma tanımadada, Google'ın beyni ve robotlarında vb. önemli bir rol oynamaktadır [27]. Tıbbi bağlamda en yaygın derin öğrenme algoritmaları, evrişim sinir ağları (CNN [*convolution neural networks*]), tekrarlayan sinir ağları, derin inanç ağları ve derin sinir ağlarıdır.

Kaynaklar

Temel kaynak: Romiti S, Vinciguerra M, Saade W, Cortajarena IA, Greco E . Artificial Intelligence (AI) and Cardiovascular Diseases: An Unexpected Alliance. Hindawi

Cardiology Research and Practice Volume 2020, Article ID 4972346, 8 pages

<https://doi.org/10.1155/2020/4972346>


- 1] S. S. Virani, A. Alonso, E. J. Benjamin et al., “Heart disease and stroke statistics-2020 update: a report from the American heart association,” *Circulation*, vol. 141, no. 9, pp. e139–e596, 2020.
- 2] T. B. Murdoch and A. S. Detsky, “e inevitable application of big data to health care,” *Journal of the American Medical Association*, vol. 309, no. 13, pp. 1351-1352, 2013.
- 3] F. Jiang, Y. Jiang, H. Zhi et al., “Artificial intelligence in healthcare: past, present and future,” *Stroke and Vascular Neurology*, vol. 2, no. 4, pp. 230–243, 2017.
- 4] K. Seetharam, N. Kagiya, and P. P. Sengupta, “Application of mobile health, telemedicine and artificial intelligence to echocardiography,” *Echo Research and Practice*, vol. 6, no. 2, pp. R41–R52, 2019.
- 5] L. E. Burke, J. Ma, K. M. J. Azar et al., “Current science on consumer use of mobile health for cardiovascular disease prevention,” *Circulation*, vol. 132, no. 12, pp. 1157–1213, 2015.
- 6] R. V. Tuckson, M. Edmunds, and M. L. Hodgkins, “Telehealth,” *New England Journal of Medicine*, vol. 377, no. 16, pp. 1585–1592, 2017.
- 7] C. Li, X. Hu, and L. Zhang, “e IoT-based heart disease monitoring system for pervasive healthcare service,” *Procedia Computer Science*, vol. 112, pp. 2328–2334, 2017.
- 8] A. Kulkarni and S. Vijaykumar, “Application of Internet of 'ings in artificial heart pacemakers and its impact on security,” *International Journal of Current Trends in Engineering & Research (IJCTER)*, vol. 2, no. 5, pp. 604–610, 2016.

- 9] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, no. 6, pp. 386–408, 1958.
- 10] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- 11] T. A. Retson, A. H. Besser, S. Sall, D. Golden, and A. Hsiao, "Machine learning and deep neural networks in thoracic and cardiovascular imaging," *Journal of Thoracic Imaging*, vol. 34, no. 3, pp. 192–201, 2019.
- 12] J. W. Benjamins, T. Hendriks, J. Knuuti, L. E. Juarez-Orozco, and P. van der Harst, "A primer in artificial intelligence in cardiovascular medicine," *Netherlands Heart Journal*, vol. 27, no. 9, pp. 392–402, 2019.
- 13] M. Alsharqi, W. J. Woodward, J. A. Mumith, D. C. Markham, R. Upton, and P. Leeson, "Artificial intelligence and echocardiography," *Echo Research and Practice*, vol. 5, pp. R115–R125, 2018.
- 14] S. Narula, K. Shameer, A. M. Salem Omar, J. T. Dudley, and P. P. Sengupta, "Machine-learning algorithms to automate morphological and functional assessments in 2D echocardiography," *Journal of the American College of Cardiology*, vol. 68, no. 21, pp. 2287–2295, 2016.
- 15] A. Madani, R. Arnaout, M. Mofrad, and R. Arnaout, "Fast and accurate view classification of echocardiograms using deep learning," *NPJ Digital Medicine*, vol. 1, no. 1, 2018.
- 16] G. Singh, S. J. Al'Aref, M. Van Assen et al., "Machine learning in cardiac CT: basic concepts and contemporary data," *Journal of Cardiovascular Computed Tomography*, vol. 12, no. 3, pp. 192–201, 2018.
- 17] B.-K. Koo, A. Erglis, J.-H. Doh et al., "Diagnosis of ischemia-causing coronary stenoses by noninvasive fractional flow reserve computed from coronary computed tomographic angiograms: results from the prospective multicenter DISCOVER-FLOW (diagnosis of ischemia-causing stenoses obtained via Noni)," *Journal of the American College of Cardiology*, vol. 58, no. 19, pp. 1989–1997, 2011.
- 18] B. L. Nørgaard, J. Leipsic, S. Gaur et al., "Diagnostic performance of noninvasive fractional flow reserve derived from coronary computed tomography angiography in suspected coronary artery disease: the NXT trial (analysis of coronary blood flow using CT angiography: next steps)," *Journal of the American College of Cardiology*, vol. 63, no. 12, pp. 1145–1155, 2014.
- 19] M. Wernick, Y. Yang, J. Brankov, G. Yourganov, and S. Strother, "Machine learning in medical imaging," *IEEE Signal Processing Magazine*, vol. 27, no. 4, pp. 25–38, 2010.
- 20] R. Cuocolo, T. Perillo, E. De Rosa, L. Ugga, and M. Petretta, "Current applications of big data and machine learning in cardiology," *Journal of Geriatric Cardiology: JGC*, vol. 16, no. 8, pp. 601–607, 2019.
- 21] S. J. Al'Aref, K. Anchouche, G. Singh et al., "Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging," *European Heart Journal*, vol. 40, no. 24, pp. 1975–1986, 2019.
- 22] R. Vidal Perez, "Utility of artificial intelligence in cardiology," *HealthManagement*, vol. 18, no. 1, 2018.

- 23] S. Shrestha and P. P. Sengupta, "Machine learning for nuclear cardiology: the way forward," *Journal of Nuclear Cardiology*, vol. 26, no. 5, pp. 1755–1758, 2019.
- 24] K. Shameer, K. W. Johnson, B. S. Glicksberg, J. T. Dudley, and P. P. Sengupta, "Machine learning in cardiovascular medicine: are we there yet?" *Heart*, vol. 104, no. 14, pp. 1156–1164, 2018.
- 25] R. Miotto, F. Wang, S. Wang, X. Jiang, and J. T. Dudley, "Deep learning for healthcare: review, opportunities and challenges," *Briefings in Bioinformatics*, vol. 19, no. 6, pp. 1236–1246, 2017.
- 26] D. Ravi, C. Wong, F. Deligianni et al., "Deep learning for health informatics," *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 1, pp. 4–21, 2017.
- [27] C. Krittanawong, H. Zhang, Z. Wang, M. Aydar, and T. Kitai, "Artificial intelligence in precision cardiovascular medicine," *Journal of the American College of Cardiology*, vol. 69, no. 21, pp. 2657–2664, 2017
-

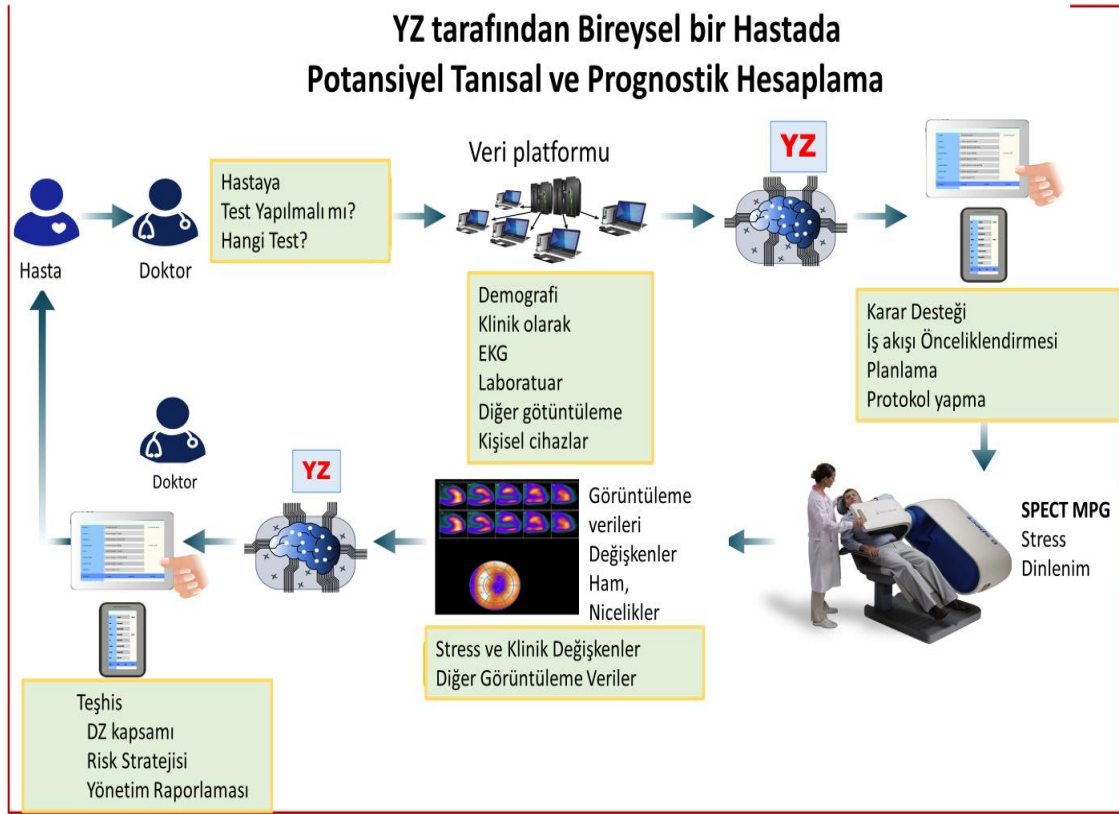
Kardiyolojide Yapay Zeka: Bugünü ve Geleceği

Evrişimli bir sinir ağının gelişiminin şematik diyagramı(Figür 1). Evrişimli sinir ağının girişi olarak ham bir sinyal kullanıldığında, sayısal değerlerin bir listesini elde etmek için fiziksel sinyal örneklenir (analogdan dijitale dönüştürülür), bunların her biri belirli bir zamandaki sinyalin genliğini temsil eder. Daha sonra dijital değerler, katman çıktısını elde etmek için her seviyedeki ağ ağırlıklarıyla evrilir, her katman sürekli olarak bir sonrakine beslenir ve son katman, nihai model çıktısını temsil eder. Ağ ağırlıkları, eğitim sırasında ağ sinyallerini bilinen çıkışlarla besleyerek ve bunları gerçek etiketler ile ağ çıkışı arasında en uygun eşleşme elde edilene kadar düzeltilerek ayarlanır




Figür 1. Evrişimli bir sinir ağının gelişiminin şematik diyagramı.

İlgilenilen duruma ve klinik özelliklerine sahip bireyleri tanımlamak için çeşitli elektronik sağlık kaydı (ESK [EMR- *electronic health record*]) veri türleri kullanılır. Veri kaynakları klinik anlatıları ve yapılandırılmış verileri içerir. Klinik anlatılardan ilgili bilgiler doğal dil işleme (DDİ [NLP-*natural language processing*]) yoluyla çıkarılır. EHR'lerden çıkarılan hasta özellikleri, bireysel hasta özelliklerine göre uyarlanmış önerileri üreten ve görüntüleyen klinik karar destek (KKD [CDS- *clinical decision support*]) sistemlerine girdi olarak sunulur (Figür 2).



Figür 2. Nükleer kardiolojide çoklu rutinlere yapay zeka (YZ) algoritmalarının potansiyel olarak dahil edilmesi




Figür 3. 12 uçlu bir EKG'den düşük ejeksiyon fraksiyonunu (EF) tespit etmek için nöral elektrokardiyogram (EKG) özellikli algoritmanın performansı. A, Doğrulama ve test veri setlerinde eğrinin altındaki alan (AUC[area under the curve]). B- Sonuçları yanlış pozitif kabul edilen hastalarda gelecekte düşük EF riski 4 kat arttı (yaşa ve cinsiyete göre ayarlanmış tehlike oranı, 4,1; %95 GA, 3,3-5,0; P<.001).

Kısaltmalar: ROC = alıcı çalışma karakteristiği (*receiver operating characteristic*); TTE = transtorasik ekokardiyogram.

Figür 3'de 12 derivasyonlu bir EKG'den düşük ejeksiyon fraksiyonunu (EF) tespit etmek için nöral elektrokardiyogram (EKG) özellikli bir algoritmanın performansı³.


- A- Doğrulama ve test veri setlerinde eğrinin altındaki alan (AUC-area under the curve).
- B- Sonuçları yanlış pozitif kabul edilen hastalarda gelecekte düşük EF riski 4 kat arttı (yaşa ve cinsiyete göre ayarlanmış hazard ratio= 4,1; %95 GA, 3,3-5,0; P<.001).

ROC = receiver operating characteristic (alıcı çalışma karakteristiği); TTE = transtorasik ekokardiyogram.



Figür 4. Yapay zekanın (YZ) kalp yetersizliğinde (KY) potansiyel kullanımları.

(A)- KY'nin önlenmesi, KY'nin yeniden kabulünün azaltılması ve KY popülasyon yönetimi dahil olmak üzere KY yönetiminde YZ'nin potansiyel rolü.(B)- KY patofizyolojisinin, hassas tedavinin ve yeni terapötiklerin aydınlatılmasında YZ'nin potansiyel rolü.



Figür 5. İlgilenilen duruma ve klinik özelliklerine sahip bireyleri tanımlamak için çeşitli elektronik sağlık kaydı (ESH [EHR]) veri türleri kullanılır. Veri kaynakları klinik anlatıları ve yapılandırılmış verileri içerir. Klinik anlatılardan ilgili bilgiler doğal dil işleme (DDİ [NLP]) yoluyla çıkarılır. EHR'lerden çıkarılan hasta özellikleri, bireysel hasta özelliklerine göre uyarlanmış önerileri üreten ve görüntüleyen klinik karar destek (KKD [CDS]) sistemlerine girdi olarak sunulur.

Temel kaynak: Francisco Lopez-Jimenez, Zach Attia, Adelaide M. Arruda-Olson, Rickey Carter, Panithaya Chareonthaitawee, Hayan Jouni, Suraj Kapa, Amir Lerman, Christina Luong, Jose R. Medina-Inojosa, Peter A. Noseworthy, Patricia A. Pellikka, Margaret M. Redfield, Veronique L. Roger, Gurpreet S. Sandhu, Conor Senecal, Paul A. Friedman. Artificial Intelligence in Cardiology: Present and Future Mayo Clinic Proceedings 2020 951015-1039DOI: ([10.1016/j.mayocp.2020.01.038](https://doi.org/10.1016/j.mayocp.2020.01.038))