

Kardiyolojide Yapay Zeka Uygulamaları

Artificial Intelligence Applications in Cardiology

© Cansın Tulunay Kaya

Ankara Üniversitesi Tıp Fakültesi, Kardiyoloji Anabilim Dalı, Ankara, Türkiye

Öz

Kardiyoloji günlük klinik pratikte teknolojinin en yoğun olarak kullanıldığı tıp dallarından biridir. Kardiyolojide yapay zeka uygulamaları 12 derivasyon EKG ve giyilebilir-taşınabilir cihazlardan gelen sinyallerin analizi ile çeşitli hastalıkların öngörülmesi, başta atriyal fibrilasyon olmak üzere aritmilerin saptanması, görüntüleme tetkikleri sırasında uygun görüntünün elde edilmesi, işlenmesi, ölçümler alınarak tanıya varılması, ses ve doğal dil analizi ile tanı, klinik risk belirleme algoritmaları ya da fenotiplendirme ile kişiye özel tıp uygulamalarının yönlendirilmesi gibi çeşitli şekillerde kullanılabilir. Şu an rutin klinik pratiğe girememiş olan bu uygulamaların değerlendirilebilmesi için klinisyenlerin dahil olduğu büyük ölçekli çalışmaların yapılması şarttır.

Anahtar Kelimeler: Yapay Zeka, Makine Öğrenmesi, Aritmi Tanıma, EKG Analizi, Giyilebilir Cihazlar

Abstract

Cardiology is one of the medical specialties that uses technology on a large scale for routine clinical care. Artificial intelligence can be applied in cardiological care in several ways such as: Predicting of various diseases by analysis of signals from 12-lead ECG and wearable-portable devices; detecting arrhythmias, especially atrial fibrillation; obtaining and processing the appropriate image during imaging examinations, making a diagnosis by taking measurements; and guiding personalized medicine practices with diagnosis through voice and natural language analysis, clinical risk determination algorithms or phenotyping. Large-scale studies involving clinicians are essential in order to evaluate these applications, which have not yet entered routine clinical practice.

Key Words: Artificial Intelligence, Machine Learning, Arrhythmia Detection, ECG Analysis, Wearable Devices

Giriş

19. yüzyılın sonlarında Einthoven tarafından elektrokardiyogramın keşfinden itibaren kardiyoloji, günlük klinik pratikte hem tanısal testler hem de tedavi edici girişimler sırasında teknolojinin en yoğun olarak kullanıldığı bilim dallarından biri olmuştur. Hastanın anamnez ve muayene bulgularından, görüntüleme ve laboratuvar testlerine, sürekli monitör takiplerinden girişimsel koroner anjiyografi bulgularına kadar sağlık bakımının her aşamasında çeşitli veriler ortaya çıkmaktadır. Sağlık bakımı sırasında yıllık 2 zettabit (2 trilyon

gigabit) verinin ortaya çıktığı tahmin edilmektedir (1). Bu değer teknoloji gelişimi ve sağlıkta dijitalleşmenin artışı ile her yıl katlanarak artmaktadır. Yapay zeka sayesinde bu dev verinin işlenmesi ve insan beyninin kapasitesinin ötesinde bilgilere ulaşılması mümkündür.

Kardiyolojide yapay zeka çeşitli şekillerde kullanılabilir (2):

- 1) Sinyal analizi - Elektrokardiyografi (EKG), giyilebilir-taşınabilir cihazlardan gelen veriler,
- 2) Görüntü analizi - ekokardiyografi, manyetik rezonans, bilgisayarlı tomografi,

Yazışma Adresi/Address for Correspondence: Cansın Tulunay Kaya
Ankara Üniversitesi Tıp Fakültesi, Kardiyoloji Anabilim Dalı, Ankara, Türkiye
Tel.: +90 3125082778 E-posta: kayac@ankara.edu.tr ORCID ID: orcid.org/0000-0002-1168-9005
Geliş Tarihi/Received: 11.11.2022 Kabul Tarihi/Accepted: 23.11.2022

©Telif Hakkı 2022 Ankara Üniversitesi Tıp Fakültesi
Ankara Üniversitesi Tıp Fakültesi Mecmuası, Galenos Yayınevi tarafından yayınlanmıştır.
Yayınlanan tüm içerik CC BY-NC-ND lisansı altındadır.



3) Ses - doğal dil analizi - elektronik hastane kayıtlarının oluşturulması-analizi, hastanın sesinden hastalık tanısı, fonokardiyografik sinyallerin değerlendirilmesi,

4) Klinik risk belirleme,

5) Hassas tıp uygulamaları - yapay zeka tarafından saptanan fenotipe göre kişiye özel tedavilerin uygulaması.

Elektrokardiyografi Temelli Yapay Zeka Uygulamaları ve Giyilebilir-Taşınabilir Teknolojiler

EKG diğer teknolojilerin aksine ucuz, taşınabilir ve kolay erişilebilir olması nedeni ile ilk uygulanmasından bir asırdan fazla geçmesine karşın kardiyoloji için temel tanısal test olma özelliğini korumaktadır. Her yıl dünya genelinde yaklaşık 200 milyon EKG kaydı alınmaktadır (3). EKG değerlendirebilmek belirli bir eğitim ve pratik yapma işidir. Hekimler daha önce öğrendikleri bilgiler doğrultusunda dalgaları değerlendirip miyokard infarktüsü/iskemisi, ritm bozuklukları, ventrikül hipertrofileri, hatta çeşitli elektrolit bozuklukları gibi durumların tanılarını EKG trasesi sayesinde koyabilmektedir. Teknolojideki tüm gelişmelere rağmen klinik pratikte halen EKG traselerinin doğrudan görsel olarak değerlendirilmesi ile tanıya gidilmektedir.

Kardiyoloji dijitalleşme açısından tıpta öncü dallardan biridir. Analog EKG'ler ilk kez 1950'li yıllarda dijital hale dönüştürülmüştür. Bu sayede 1960'larda EKG sinyalleri bilgisayarlara aktarılacak ilk bilgisayar aracılı EKG yorumlama algoritmaları geliştirilmiştir (4). Bilgisayar tarafından EKG yorumlanmasındaki ilk algoritmalar EKG değerlendirmede uzman kişilerce yazılan basitleştirilmiş kurallar aracılığı ile yapılmakta idi. 1980'ler sonrası istatistiksel yöntemler ve Bayesian analiz bilgisayarlı EKG analizine entegre edildi. Bu sayede hastanın demografik bilgileri ile belirlenen test-öncesi olasılıklar da analize eklenerek daha güvenilir bir algoritma oluşturulması hedeflenmiştir. Günümüzde EKG cihazlarına entegre bilgisayarlar sinyalleri olarak analogdan dijitalle çevirmekte, parazitleri filtrelemekte, dalga formlarını tanıyarak p-dalgası QRS kompleksi ya da T dalgalarının başlangıç ve bitişlerini belirleyebilmekte ve bu sayede PR, QRS ya da QT intervallerini hesaplayabilmektedir. Bütün gelişmelere karşın halen kural-bazlı bilgisayarlı EKG değerlendirme algoritmalarının geliştirilmesi gereken yönleri vardır. Öncelikle sinüs ritmini algılamakta ve sinüs ritminde interval hesabında gayet duyarlı olan bu algoritmalar sinüs dışı ritimler ve pil ritimlerini algılamakta pek duyarlı değildir (5), üreticiler arası bir standardizasyon mevcut değildir ve ST yükselmeli miyokard infarktüsü tanısında yalancı negatif ve pozitiflik oranları arasında belirgin değişkenlik mevcuttur (6). Bu algoritmaların çoğunda çıktı uzman kardiyologların oluşturduğu bir kurulun ortak kararı ile belirlenmekte ve insan kararı altın standart olarak kabul edilmektedir, ancak bu uzmanların da karar vermekte fikir ayrılığı yaşadığı durumlar olabilmektedir.

10 saniyelik bir zaman dilimini kaydeden standart 12 derivasyonlu EKG üzerinde dahi her bir atımı ve dalgayı tek tek değerlendirmek çok zorken monitör ya da holter gibi daha uzun süreli kayıtlardan bunu yapabilmek çok büyük emek ve zaman gerektirmektedir. Bütün bu nedenler ile yapay zekanın özellikle derin öğrenmenin EKG değerlendirilmesine entegre edilmesi korunma-tanı-tedavi ve prognoz belirlenmesi gibi tıbbi bakımın tüm basamaklarına katkıda bulunacaktır. EKG kolay çekilebilen, dijital olarak kolay depolanabilen ve arşivlenebilen bir tetkiktir, bu sayede çok büyük EKG veritabanları mevcuttur. Son yıllarda EKG analizindeki gelişmelerin çoğu derin nöral ağları içeren modeller üzerinden olmuştur. Derin nöral ağlar sayesinde büyük miktardaki veri ile beslenen bilgisayar, ham EKG verilerini inceleyip değişkenler içinde var olan çeşitli kalıpları saptayabilmekte, ilgilenilen konu ile ilgili olan ya da gerekli olmayan nitelikleri belirleyip değerlendirebilmekte ve karara varabilmektedir. Makine tarafından saptanan kalıp ya da özellik insan gözünün algılayamayacağı bir özellik de olabilmektedir. Yakın zamanda uzmanlar tarafından çıktısı etiketlenen EKG'lerin derin nöral ağlar ile oluşturulan modeller ile analizi üzerine yapılan çeşitli çalışmalarda derin öğrenme ile tek derivasyon ya da 12-derivasyonlu EKG'ler üzerinde 12 farklı ritm anormalliğinin kardiyoloğa yakın doğrulukla saptanabileceği gösterilmiştir (7,8).

Derin nöral ağlar ve denetimsiz makine öğrenmesi sayesinde EKG içindeki saklı özellikler aracılığı ile insan gözü ile saptanamayan durumların tespiti mümkündür. Örneğin klinisyenlerin T sivrileşmesi, QRS genişlemesi gibi bulgulara dayanarak hiperpotasemi tanısı koyma olasılıkları %40'tan az iken derin öğrenme sayesinde EKG çıktılarından %90 civarı bir duyarlılıkla hiperpotasemi varlığı tahmin edilebilmektedir (9).

Yaklaşık 45 bin hastanın EKG ve ekokardiyografi verileri ile derin öğrenme ile eğitilen yapay sinir ağı aracılığı ile 12 derivasyon EKG üzerinden ejeksiyon fraksiyonu (EF) %35 altında olan hastalar %86 duyarlılıkla saptanabilmektedir (10). Kwon ve ark.'nın (11) araştırmasında EKG kayıtlarından ciddi aort darlığı varlığı olasılığını oldukça duyarlı bir şekilde öngörmek mümkün olmuştur. Yakın zamanda yayınlanan bir diğer çalışmada derin öğrenme algoritmaları ile EKG analizinin orta ya da ciddi aort darlığı, aort yetmezliği ya da mitral yetmezliğinin ayrı ayrı ya da bir arada varlığını %78 duyarlılık %73 özgüllük ile saptayabildiği ve negatif prediktif değerinin %97 olduğu saptanmıştır (12). Bu çalışmada aort darlığı tanısında diğer kapak lezyonlarına göre daha fazla başarı elde edilmiştir. Bunun sebebi aort darlığında ortaya çıkan kronik ilerleyici konsantrik sol ventrikül hipertrofisine ait EKG bulgularının daha belirgin olmasından kaynaklanabilir.

Lee ve ark. (13) yaptığı bir çalışmada ise peripartum dönemde çekilen EKG aracılığı ile peripartum kardiyomyopati olasılığı duyarlı bir şekilde tanınabilmektedir.

Ekokardiyografiye ulaşımın mümkün olmadığı durumlarda bu gibi modeller aracılığı ile elde edilen veriler sayesinde hangi hastaların ileri tetkik için sevk edilmesi gerektiği gibi kararlar daha kolay verilecek gereksiz tetkikler engellenmiş olacaktır.

Atrial Fibrilasyonun Saptanmasında Yapay Zeka Uygulamaları

Atrial fibrilasyon (AF) erişkin popülasyonda en sık görülen aritmi olup inme, kalp yetersizliği ve mortalite ile yakından ilişkilidir (14). Çoğu zaman asemptomatik olduğu ve hastaların büyük kısmında başlangıçta paroksizmal ataklar halinde görüldüğünden 10 saniyelik tek bir EKG ile saptanması güçtür. EKG trasesinde AF bulursa bile günümüzde kullanılan kural temelli algoritmalar ile bilgisayar yorumlamasında tanısız hata oranı oldukça yüksektir (15). Açıklanamayan embolik kökenli inme hastalarında antiplatelet ya da antikoagülan tedavi seçiminde AF varlığının bilinmesi çok önemlidir. AF olasılığının hızlı-güvenilir ve ucuz bir biçimde saptanabilmesini sağlayan yöntemlerin geliştirilmesi, mortalite ve morbiditenin önemli sebebi olan bu aritminin erken ve uygun şekilde tedavi edilebilmesini sağlayacaktır.

AF gelişmeden önceki yapısal değişiklikler örneğin miyosit hipertrofi-fibrozisi, atriyal genişleme gibi durumlar EKG'de gözle değerlendirilemeyen küçük değişikliklere sebep oluyor olabilir. Bu değişiklikleri saptayabilen derin öğrenme modelleri daha AF gelişmeden gelişimi öngörebilir. Örneğin Attia ve ark.'nın (16) çalışmasında sinüs ritmindeki EKG'lerden AF bulunma olasılığı öngörülebilmektedir. Yine yapay zeka ile değerlendirilen ve AF riski yüksek bulunan hastaların daha uzun vadeli taramaya yönlendirilmesi ile AF tanısı daha yüksek duyarlılıkla konulabilmektedir (17).

AF'nin ticari olarak satılan giyilebilir-taşınabilir cihazlarla tespiti son yıllarda özellikle popülerite kazanmıştır. Fotopletismografi ışık kaynağı ve bir fotodedektör aracılığı ile nabız basınç dalga formlarının değerlendirilmesini sağlayan bir yöntemdir. Atımlar arası değişkenlik ve dalga formu şekillerinin değişken olması ile fotopletismografik yöntemle AF tanısı koyulabilmektedir (18). Kola takılabilen kol bandı ya da akıllı saat formundaki cihazlarla yapılan fotopletismografik analizlerle AF taraması ile ilgili çalışmalarda Huawei akıllı saat ile %0,23 oranında hastada AF sinyali alınmış ve bu hastaların %87'sinde takipte irregüler ritmin AF olduğu kesinleştirilmiştir (19). Benzer şekilde Apple-Heart çalışmasında ise Apple akıllı saatlerle %0,52 oranında AF sinyali alınmış, bunu hastalardan kabul edenlere 7 günlük EKG kaydı alınmış ve %34 oranında AF saptanmıştır. Düzensiz ritm uyarısı varlığında ritmin %84 oranında AF olduğu gösterilmiştir (20). Giyilebilir cihazlar ile fotopletismografi dışında çeşitli algoritmalar ile EKG kayıtları da alınabilmektedir. Bu kayıtların değerlendirilme algoritmalarında AF tanımadaki duyarlılık %90'ın üzerindedir (21). Akıllı saatler

gibi giyilebilir EKG çeken cihazların yaygınlaşması ile EKG veritabanları genişleyecek ve bu cihazların klinik kullanımdaki yerleri belirlenecektir.

Kardiyak Görüntüleme Yapay Zeka

Kardiyak görüntüleme yöntemleri arasında en sık kullanılanı ekokardiyografidir. Klinik pratikte tanı ve tedavinin yönlendirilmesinde paha biçilemez bir değere sahiptir. Ekokardiyografik görüntülemenin kaliteli görüntünün elde edilmesi, görüntü penceresinin tanınması, ölçümlerin alınması ya da tanıya ulaşılması gibi farklı basamaklarında yapay zeka kullanılabilir (22).

2020 yılında kullanıcıyı doğru görüntüyü alması için yönlendiren yapay zeka ile çalışan ilk ultrason yazılımı FDA onayı almıştır (23). Bu yazılım sayesinde başlangıç düzeyindeki kullanıcıların doğru ekokardiyografik görüntüleri çıkarması mümkün olmaktadır. Daha önce ekokardiyografik görüntü alma deneyimi olan hemşirelerin bu yazılımın yönlendirmesi ile aldığı görüntülerin yeterliliğinin uzman görüntülemeciler tarafından değerlendirildiği bir çalışmada, alınan görüntülerin sol ventrikül ve sağ ventrikül boyutları ve fonksiyonları ile perikard sıvısının varlığını değerlendirmek için yeterli olduğu sonucuna ulaşılmıştır (24). Doğru bir değerlendirme ve doğru ölçümler için uygun görüntünün çıkarılması çok önemlidir.

Madani ve ark.'nın (25) araştırmasında denetlenmiş derin öğrenme ile oluşturulan model 15 farklı ekokardiyografik pencereyi doğru şekilde sınıflayabilmiştir. Benzer şekilde Zhang ve ark.'nın (26) araştırmasında derin öğrenme temelli model görüntü pencerelerini doğru şekilde tanımış ve deneyimli görüntülemecilerin yaptığı şekilde her bir pencerede miyokardın segmentlerini belirleyebilmiştir. Bu segmentasyon sayesinde boşluk hacimleri, kütle, EF ve hatta miyokardiyal strain değerlerini güvenilir bir şekilde elde etmek mümkün olmuştur (26). Echonet-RCT çalışmasında EF saptanmasında yapay zeka aracılığı EF hesaplama modelinin ekokardiyografi teknisyenlerine göre uzman kardiyologlara daha yakın bir sonuç verdiği gösterilmiştir (27). Tanı koyma aşamasında sporcu kalbi ile hipertrofik kardiyomiyopatinin ayrımı (28), konstriktif perikardit-restriktif kardiyomiyopati ayrımı (29), mitral yetmezliğin derecelendirmesi (30) gibi çeşitli alanlarda araştırmalar yürütmektedir.

Kardiyak görüntüleme alanındaki çalışmalar ekokardiyografi ile sınırlı olmayıp, koroner BT anjiyografide ciddi darlıkların belirlenmesi için de kullanılabilir. BT aracılı koroner fraksiyonel akım rezervinin makine öğrenmesi modeli ile invaziv fraksiyonel akım rezerv ile karşılaştırılabilir sonuçlar elde edilmiş yalnızca görsel değerlendirmeye göre lezyonun ciddiyet sınıflaması daha büyük doğrulukla gerçekleştirilebilmiştir (31). Yapay zeka uygulamaları MR görüntüleme ya da nükleer kardiyoloji alanında da hızla çalışılmaktadır.

Kardiyolojide Diğer Yapay Zeka Uygulamaları

Yapay zeka klinik tanı-destek sistemlerine entegre edilerek özellikle imkanların kısıtlı olduğu durumlarda tanı-triyaj açısından yardımcı olabilir. Kalp yetersizliği hastalarında hastane yatışlarını ya da kardiyak resenkronizasyon tedavisine yanıtız olacak hastaları öngörülebilir (32,33).

Yapay zeka kardiyolojide fenotiplendirme ya da risk belirleme amacıyla da kullanılabilir. Örneğin elektronik hastane kayıtları üzerinden, ya da ekokardiyografi bulgularından yapılan araştırmalarda korunmuş EF kalp yetersizliğinde klinik olarak farklı 3 alt fenotipin olduğu ve bu fenotiplerin sağkalımlarının birbirlerinden farklı olduğu saptanmıştır (34).

Yapay zeka temelli ses analizi de kardiyolojide kendine uygulama alanı bulmaya adaydır. Örneğin kalp yetersizliği vokal kordlarda ödeme neden olabilir ya da pulmoner ödem solunum paternini ya da konuşmayı etkileyebilir bu bulgular ses analizi ile saptanarak ya da fonokardiyografi aracılığı ile elde edilen ses sinyalleri yapay zeka sayesinde analiz edilip kalp yetersizliği tanısı koymak mümkün olabilmektedir (35).

Yapay zeka aracı modeller hassas tıp-kışıye özel tedavi uygulamalarına kılavuzluk edebilir (36).

Kardiyolojide Yapay Zeka Uygulamalarının Geleceği

Yapay zekanın bütün bu potansiyeline rağmen henüz rutin klinik uygulamalarda kendine yer bulamamıştır. Bunun birden fazla sebebi mevcuttur. Birincisi şu ana kadar özellikle görüntüleme alanında yapılan çalışmalarda elde edilen çoğu veri konseptin kanıtlanması için yapılan küçük çalışmalardan elde edilmiş olup, birçoğu dış validasyondan geçmemiş olduğundan genellenemeyebilir. Bir diğeri sebep ise "kara kutu" problemi olarak adlandırılan algoritmaların çok komplike olmasından dolayı bazen yapay zeka uzmanlarının bile makinenin neden belirli bir kararı verdiğini açıklayamaması durumudur. Hayati kararlar alınacağı zaman kararların altında yatan sebeplerin bilinmesi çok önemlidir (37).

Sonuç

Geliştirilen modellerin klinik kullanıma girebilmesi için klinikteki son-nokta kullanıcısı olan hekimlerin yapay zeka çalışmalarında aktif rol alması çok önemlidir. Büyük hasta gruplarında yapılacak klinik araştırmalar sonrası yapay zeka ile ilgili uygulamaların klinik pratikte daha sık karşımıza çıkacağı öngörülebilir.

Kaynaklar

1. Quer G, Arnaout R, Henne M, et al. Machine Learning and the Future of Cardiovascular Care: JACC State-of-the-Art Review. *J Am Coll Cardiol.* 2021;77:300-313.
2. Van den Eynde J, Lachmann M, Laugwitz KL, et al. Successfully implemented artificial intelligence and machine learning applications in cardiology: State-

- of-the-art review. *Trends Cardiovasc Med.* 2022;S1050-1738(22)00012-3.
3. Reichlin T, Abächerli R, Twerenbold R, et al. Advanced ECG in 2016: is there more than just a tracing? *Swiss Med Wkly.* 2016;146:w14303.
4. Hongo RH, Goldschlager N. Status of computerized electrocardiography. *Cardiol Clin.* 2006;24:491-504.
5. Guglin ME, Thatai D. Common errors in computer electrocardiogram interpretation. *Int J Cardiol.* 2006;106:232-237.
6. Schläpfer J, Wellens HJ. Computer-Interpreted Electrocardiograms: Benefits and Limitations. *J Am Coll Cardiol.* 2017;70:1183-1192.
7. Chang KC, Hsieh PH, Wu MY, et al. Usefulness of Machine Learning-Based Detection and Classification of Cardiac Arrhythmias With 12-Lead Electrocardiograms. *Can J Cardiol.* 2021;37:94-104.
8. Hannun AY, Rajpurkar P, Haghpanahi M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med.* 2019;25:65-69.
9. Galloway CD, Valys AV, Shreibati JB, et al. Development and Validation of a Deep-Learning Model to Screen for Hyperkalemia From the Electrocardiogram. *JAMA Cardiol.* 2019;4:428-436.
10. Attia ZI, Kapa S, Lopez-Jimenez F, et al. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med.* 2019;25:70-74.
11. Kwon JM, Lee SY, Jeon KH, et al. Deep Learning-Based Algorithm for Detecting Aortic Stenosis Using Electrocardiography. *J Am Heart Assoc.* 2020;9:e014717.
12. Elias P, Poterucha TJ, Rajaram V, et al. Deep Learning Electrocardiographic Analysis for Detection of Left-Sided Valvular Heart Disease. *J Am Coll Cardiol.* 2022;80:613-626.
13. Lee Y, Choi B, Lee MS, et al. An artificial intelligence electrocardiogram analysis for detecting cardiomyopathy in the peripartum period. *Int J Cardiol.* 2022;352:72-77.
14. Gladstone DJ, Spring M, Dorian P, et al. Atrial fibrillation in patients with cryptogenic stroke. *N Engl J Med.* 2014;370:2467-2477.
15. Lindow T, Kron J, Thulesius H, Ljungström E, Pahlm O. Erroneous computer-based interpretations of atrial fibrillation and atrial flutter in a Swedish primary health care setting. *Scand J Prim Health Care.* 2019;37:426-433.
16. Attia ZI, Noseworthy PA, Lopez-Jimenez F, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *Lancet.* 2019;394:861-867.
17. Noseworthy PA, Attia ZI, Behnken EM, et al. Artificial intelligence-guided screening for atrial fibrillation using electrocardiogram during sinus rhythm: a prospective non-randomised interventional trial. *Lancet.* 2022;400:1206-1212.
18. Sehrawat O, Kashou AH, Noseworthy PA. Artificial intelligence and atrial fibrillation. *J Cardiovasc Electrophysiol.* 2022;33:1932-1943.
19. Guo Y, Wang H, Zhang H, et al. Mobile Photoplethysmographic Technology to Detect Atrial Fibrillation. *J Am Coll Cardiol.* 2019;74:2365-2375.
20. Perez MV, Mahaffey KW, Hedlin H, et al. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med.* 2019;381:1909-1917.
21. Bumgarner JM, Lambert CT, Hussein AA, et al. Smartwatch Algorithm for Automated Detection of Atrial Fibrillation. *J Am Coll Cardiol.* 2018;71:2381-2388.
22. Kusunose K. Steps to use artificial intelligence in echocardiography. *J Echocardiogr.* 2021;19:21-27.
23. Voelker R. Cardiac Ultrasound Uses Artificial Intelligence to Produce Images. *JAMA.* 2020;323:1034.
24. Narang A, Bae R, Hong H, et al. Utility of a Deep-Learning Algorithm to Guide Novices to Acquire Echocardiograms for Limited Diagnostic Use. *JAMA Cardiol.* 2021;6:624-632.
25. Madani A, Arnaout R, Mofrad M, et al. Fast and accurate view classification of echocardiograms using deep learning. *NPJ Digit Med.* 2018;1:6.
26. Zhang J, Gajjala S, Agrawal P, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. *Circulation.* 2018;138:1623-1635.

27. D. O. EchoNet-RCT: Safety and Efficacy Study of AI LVEF. Presented at: ESC 2022 August 27, 2022 Barcelona, Spain. 2022.
28. Narula S, Shameer K, Salem Omar AM, et al. Machine-Learning Algorithms to Automate Morphological and Functional Assessments in 2D Echocardiography. *J Am Coll Cardiol*. 2016;68:2287-2295.
29. Sengupta PP, Huang YM, Bansal M, et al. Cognitive Machine-Learning Algorithm for Cardiac Imaging: A Pilot Study for Differentiating Constrictive Pericarditis From Restrictive Cardiomyopathy. *Circ Cardiovasc Imaging*. 2016;9:e004330.
30. Jeganathan J, Knio Z, Amador Y, et al. Artificial intelligence in mitral valve analysis. *Ann Card Anaesth*. 2017;20:129-134.
31. Coenen A, Kim YH, Kruk M, et al. Diagnostic Accuracy of a Machine-Learning Approach to Coronary Computed Tomographic Angiography-Based Fractional Flow Reserve: Result From the MACHINE Consortium. *Circ Cardiovasc Imaging*. 2018;11:e007217.
32. Gupta MD, Kunal S, Girish MP, et al. Artificial intelligence in cardiology: The past, present and future. *Indian Heart J*. 2022;74:265-269.
33. Kalscheur MM, Kipp RT, Tattersall MC, et al. Machine Learning Algorithm Predicts Cardiac Resynchronization Therapy Outcomes: Lessons From the COMPANION Trial. *Circ Arrhythm Electrophysiol*. 2018;11:e005499.
34. Shah SJ, Katz DH, Selvaraj S, et al. Phenomapping for novel classification of heart failure with preserved ejection fraction. *Circulation*. 2015;131:269-279.
35. Nahar JK, Lopez-Jimenez F. Utilizing Conversational Artificial Intelligence, Voice, and Phonocardiography Analytics in Heart Failure Care. *Heart Fail Clin*. 2022;18:311-323.
36. Cikes M, Sanchez-Martinez S, Claggett B, et al. Machine learning-based phenogrouping in heart failure to identify responders to cardiac resynchronization therapy. *Eur J Heart Fail*. 2019;21:74-85.
37. Kagiya N, Tokodi M, Sengupta PP. Machine Learning in Cardiovascular Imaging. *Heart Fail Clin*. 2022;18:245-258.