

REVIEW

Volume:2 Issue:2 Year:2024

<https://doi.org/10.5281/zenodo.13142328>

Kalp Hastalıklarında Yapay Zeka Kullanımı

Use of Artificial Intelligence in Heart Diseases

 Ömer Göç¹¹Harran Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulu, Perfüzyon Teknikleri Programı, Şanlıurfa, Türkiye

ÖZET

Kardiyovasküler hastalıklar dünya çapında ölüm oranlarına bakıldığında en yaygın ölüm nedenidir. Ölümüne sebebiyet veren kalp rahatsızlıklarının teşhis ve tedavisinde farklı biyomedikal teknolojiler kullanılmaktadır. Bu biyomedikal teknolojilerden biri de Yapay Zeka kullanımıdır. Yakın gelecekte, makine öğrenimi, derin öğrenme ve bilişsel hesaplama gibi Yapay Zeka teknikleri, kardiyovasküler hastalıkların teşhis ve tedavisinde kritik bir rol oynayabilir. Bu hastalıkların tanısında hassas sonuçlar ortaya çıkarabilir.

Anahtar Kelimeler: Kalp Hastalıkları, Yapay Zeka.

ABSTRACT

Cardiovascular diseases are the most common cause of death worldwide. Different biomedical technologies are used in the diagnosis and treatment of heart diseases that cause death. One of these biomedical technologies is the use of Artificial Intelligence. In the near future, artificial intelligence techniques such as machine learning, deep learning and cognitive computing may play a critical role in the diagnosis and treatment of cardiovascular diseases. It can produce sensitive results in the diagnosis of these diseases.

Keywords: Heart Diseases, Artificial Intelligence.

GİRİŞ

Kardiyovasküler hastalıkların teşhis ve tedavisinde, yetersiz hasta bakımı, teknoloji ve zamanın aşırı kullanımı, yüksek tedavi maliyetleri ve yüksek ölüm oranları gibi çeşitli zorluklarla karşılaşmaktadır. Klinik açıdan başarılı sonuçlar alabilmek için hekimlere doğru ve etkin veri akışının sağlanması gerekmektedir. Bunu kolaylaştırmak otomatik ve tahmine dayalı doğru veri analizleri ile mümkün olabilmektedir. İnsan bağırsak mikrobiyom dizilimi, kardiyak görüntüleme gibi veriler analiz edilmesi oldukça güç büyüklükte olup heterojendir ve çok hızlı değişkenlik göstermektedir (1). Yapay Zeka (YZ), büyük veriden yararlanma ve gelişmiş hasta bakımında kullanılma potansiyeline sahiptir. Kardiyovasküler hastalıklar çoklu genetik etkiler, çevresel etmenler ve davranışsal faktörlerden doğrudan etkilendiğinden doğası dolaylı karmaşık ve heterojendir. Şu anda kardiyovasküler risk etmenlerini doğru ve etkili bir şekilde tahmin etmek için YZ kullanılabilir (2). YZ, kardiyak görüntüleme tekniklerinden ekokardiyografi, bilgisayarlı tomografi, kardiyak emar ve elektrokardiyogram kayıtlarının bir algoritma ile birleştirilmesi yoluyla kardiyak rahatsızlıkların teşhis ve tedavisinde kullanılmaktadır.

Yapay Zeka

YZ, Makine Öğrenimi ve onun alt türü olan Derin Öğrenme gibi araçları kullanarak insan zekasına bağlı görevleri yerine getirir. YZ tıp alanında tanıda devrim yaratmak için giderek daha fazla kullanılıyor, tedavi, risk tahmini, klinik bakım ve ilaç keşfi uygulamalarında başarı oranını arttırmaktadır. YZ, perspektif, semantiği öğrenme ve çeşitli algoritmalar ve bilişsel hesaplamalar kullanarak bir analiz formüle ederek insan zekasına bağlı görevleri yerine getirme yeteneğine sahiptir (3). YZ, denetimli, denetimsiz ve yeniden güçlendirme olarak sınıflandırılabilen öğrenme kavramını kullanır. Makine öğrenimi YZ'nin çekirdeğidir. Karar vermek için eğitim verileri ve program algoritmalarını kullanır (4). Yaygın olarak kullanılan sınıflandırma modelleri arasında İkili, Çok sınıflı, Çok etiketli ve Dengesiz Sınıflandırma yer alır. Çoklu sınıf, ikiden fazla etiket içeren görevleri sınıflandırmak için karar ağacı, destek vektör makinesi, rastgele orman ve gradyan artırma gibi algoritmaları kullanır. Çoklu etiket, iki

Corresponding Author: Ömer Göç, e-mail: omergoc@harran.edu.tr

Received: 16.02.2024, Accepted: 23.04.2024, Published Online: 01.08.2024

Cited: Göç Ö. Use of Artificial Intelligence in Heart Diseases. Anatolia Cor. 2024;2(2):16-22.

<https://doi.org/10.5281/zenodo.13142328>The journal is licensed under a [Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

veya daha fazla sınıfı olan görevleri sınıflandırır. Eşit olmayan sınıf etiketleri dağıtılmış görevler Dengesiz sınıflandırma modeli kullanılarak sınıflandırılır. (5) Derin Öğrenme (DL), makine öğrenimi algoritmasının bir sınıfıdır. Türetilmiş sinir ağları gibi daha üst düzey özellikler kullanır. İnsan beyninin bir modelinden bir bilgisayarın karmaşık hiyerarşik temsili okumak, oluşturmak ve öğrenmek için sistem oluşturur (6). Girdi verilerinin daha bileşik bir çıktı verisine dönüştürülmesini içerir. Genetik yatkınlık, ateroskleroz gibi kardiyovasküler hastalıkların gelişiminde önemli bir faktördür. Derin Öğrenme ağlarının kullanımı gibi gelişmiş teknikler, büyük ölçekli genom çapında bir araştırma yoluyla ileri koroner arter kalsiyumunu tahmin etmek için kullanılabilir (7). Derin Öğrenme, Yapay Sinir Ağı, Evrimsel Sinir Ağı ve Yapay Sinir Ağı olarak alt bölümlere ayrılabilir.

Derin Öğrenme

Derin öğrenme, girdilerden otomatik tahminler üretebilen çok katmanlı yapay nöronal ağlar kullanarak insan beyninin çalışmasını taklit eder. Derin öğrenme son zamanlarda kardiyovasküler tıpta, daha spesifik olarak da kardiyovasküler görüntüleme uygulanmaktadır.

Bir teşhis için öngörücü bir model oluşturmak üzere önceden hesaplanmış özellikleri kullanan klasik makine öğreniminin aksine veya prognostik görev, derin öğrenme eşzamanlı olarak ilgili özellikler ve giriş görüntülerinden istenen sonuca kadar bir tahmin modeli oluşturur (8). Konvolüsyonel sinir ağı (CNN) sinir ağına bir konvolüsyon işlemi kullanan kardiyak görüntü analizinde en yaygın kullanılan mimaridir. Şu anda, CNN ve CNN türevi ağlar kardiyak görüntülerde algılama, segmentasyon ve sınıflandırmada yaygın olarak kullanılmaktadır (9). Tekrarlayan sinir ağı (RNN), genellikle sıralı verileri işlemek için kullanılan bir başka sinir ağı türüdür. Yaygın olarak kullanılan RNN yapıları ise uzun kısa vadeli belleklerdir (LSTM) (10). Kardiyak görüntüleme MRI gibi birçok sıralı veri yapısı vardır. RNN özellikle aritmisi olan hastalar ve nefes tutma zorluğu yaşayan hastalarda kardiyak görüntüleri işlemek için, hatta gelişmiş teknikler bile daha iyi görüntüler oluşturamazlar (11,12).

Algoritmaların Uygulama Görevleri

YZ algoritmalarının kardiyak görüntülemeye uygulanması üç bölümden oluşur: Algılama, segmentasyon ve sınıflandırma. Bir görüntü algılama görevinde, koroner plak gibi bir nesne, daha ileri işlemler için tanımlanmalıdır. Algılama için, CNN içinde iki boyutlu veya üç boyutlu görüntü girişleri kullanılarak hedef yapıyı aramak için bir sınırlayıcı kutu kullanır. Şüpheli yapıları içeren alt görüntüler elde edilir ve doğru veya yanlış hedef arasında ayırım yapmak için başka bir CNN modeli yapılır. Son olarak, tespit edilen hedef yapıların koordinatları nihai çıktı olarak elde edilir. Xu ve arkadaşları miyokard enfarktüsünü tespit etmek için RNN kullandı. Kardiyak MR sekanslarının alan incelenmesi genel doğruluk %94.35 olarak tespit edildi (13). Guo ve arkadaşları, bir koroner arter ağacının merkez hattı mesafe haritasını çıkarmak ve minimal yol çıkarıcı ile dal uç noktalarını hesaplamak için yerel bir FCN birleştirdi (14). Koroner arter dalları ve hasta düzeyinde iyileştirme merkez hattı çıkarma başarı oranı %54,3'ten %88,8'e çıkmıştır.

Görüntü segmentasyonu, kardiyak görüntülerin bölümlere ayrılması işlemidir. Belirli yapıları ayırmak için görüntüyü farklı bölgelere ayırmak veya lezyonlar, genellikle özellik için bir ön işleme adımı çıkarma ve sınıflandırma olarak kullanılır

Kamu Veritabanı

Yüksek kaliteli görüntü veritabanının mevcudiyeti YZ algoritmalarının geliştirilmesi için kritik öneme sahiptir. Verilerin kapsamı ve kalitesi algoritmanın doğruluğu, genelleştirilebilirliği sağlamlığını belirler (15). Kamuya açık veritabanlarının yakın zamandaki mevcudiyeti araştırmacıları yeni YZ algoritmaları geliştirmeye teşvik ediyor. Bir görüntü veritabanının oluşturulması oldukça zordur, ayrıca hasta mahremiyeti korunmalı ve sağlık bilgileri gizlenmelidir. Derin öğrenme algoritmalarının geliştirilmesi için veritabanı boyutu ve hasta popülasyonunun kapsamı sağlanmalıdır, bu da genellebilirlik için kritik bir durumdur. Aynı zamanda büyük bir etiketleme için tıbbi görüntü sayısı, deneyimli radyologların uzmanlığını gerektirir. Kardiyoloji alanında elektronik sağlık kayıtlarından kardiyak aritmi, kalp krizi tahminleri gibi büyük veri tabanları oluşturma çalışmaları devam ediyor (16).

Bu veritabanları yüzlerce değişken içerir ve bu değişkenler yeni YZ sistemleri geliştirmek için kullanılabilir. Kardiyak görüntü veri tabanlarının geliştirilmesine yönelik girişimler zaman zaman oldu. 2016 yılında Kaggle sol ventrikül için ikinci Data Science Bowl'u düzenledi. 1000'den fazla kardiyak MR görüntüsünün kullanıldığı hacim değerlendirmesi için Ulusal Sağlık Enstitüleri ve Ulusal Çocuk Tıp Merkezi tarafından veritabanı sağlanmıştır (17). Burada amaç, kalp atışlarını otomatik olarak ölçmek, hacimleri ve ejeksiyon fraksiyonlarını hesaplamak için algoritmalar geliştirmektir. Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Müdahale Derneği 2017 yılında Otomatik Kardiyak Tanı Yarışması'nı düzenledi sol ventrikül endokardının otomatik segmentasyonu için ve epikard ve 100 denekten oluşan bir eğitim seti sağlandı (18). Ancak YZ sonuçlarının büyük bir dezavantajı ise bu veri tabanlarının heterojenlikten muzdarip olması ve düşük kalite, kardiyak tedavinin uygulanabilirliğini kısıtlamaktadır.

Kalp Hastalıkları Ve Yapay Zeka

Kardiyovasküler hastalıklardaki evrim, tedavi ve teşhis tekniklerinde ilerlemeler gerektirmektedir, bu nedenle YZ artık kardiyovasküler tıp alanına hızla dahil ediliyor. YZ tıbbi teşhis, tedavi, risk tahmini, klinik bakım ve diğer alanlarda devrim yaratma potansiyeline sahiptir.

Geniş veri tabanlarının yorumlanması yoluyla ilaç keşfi insan beynine kıyasla daha verimli bir şekilde çalışır (19,20). Kardiyak anjiyografi, ekokardiyografi ve elektrokardiyogram (EKG) gibi Derin Öğrenme tabanlı tanı yöntemlerinin kullanımı kalp yetmezliği, miyokard enfarktüsü, aritmi ve kalp kapak hastalığı gibi kardiyovasküler hastalıkların teşhisinde devrim yaratan rolü ile kardiyovasküler tıp alanında önemli bir rol oynamıştır. Paroksizmal Supraventriküler Taşikardi (PSVT) yaşam kalitesini kötüleştirebilen sporadik, ani ve tekrarlayan bir taşikardidir. Tedavi edilebilir olmasına rağmen, anlık ataklar sırasında ortaya çıkması nedeniyle teşhis edilmesi zordur. Ancak, Derin öğrenme teknikleri tabanlı EKG kullanımı PSVT'nin erken teşhisini mümkün kılmıştır. YZ tabanlı araçların ve Manyetik rezonans görüntüleme (MRI), intravasküler ultrason, optik koherens tomografi (OCT) ve tek foton emisyon bilgisayarlı tomografi (SPECT) gibi tıbbi cihazların kullanımı klinisyenlere potansiyel ölümcül kardiyovasküler hastalıkların ayrıntılı ve hatasız teşhisine olanak sağlamaktadır (21). Ayrıca, makine öğrenimi tabanlı YZ'nin kullanımı kardiyovasküler hastalıkları olan hastalarda 5 yıllık sağ kalım oranını daha doğru tahmin ettiği (%80) kanıtlanmıştır. Bu oran diğer tekniklerde %60'dır (22). YZ'nin kardiyovasküler alanda ortaya çıkışı EKG, Eko gibi tanı yöntemleri aracılığıyla tıp, anjiyografi ve robotik gibi modern tekniklerin kullanımı kardiyovasküler hastalıkların tedavisinde mortaliteyi belirgin şekilde azaltmıştır. YZ'nin hekimlerin yerini alması pek olası değildir, ancak YZ hekimlerin klinik yargılarını geliştirmelerine yardımcı olabilecek ve hastalıkların kesin teşhisini sağlayabilecek önemli bir araçtır.

Kalp Kapak Hastalığı

Birçok kalp kapak hastalığı uzun asemptomatik dönemler içerir (23). Ancak belirtiler ortaya çıktığında, ölüm oranı önemli ölçüde artmaktadır (24). Asemptomatik hastalarda takip ve semp-tomatik hastalarda kapak replasmanı genellikle iyi sonuçlanır (23). Bununla birlikte, bu asemptomatik hastaların nasıl tespit edileceği konusunda zorluk yaşanmaya devam etmektedir. Ekokardiyografi kalp kapak hastalığı tanısını doğrulamak için altın standarttır, ancak tarama testleri için uygun değildir (25). Bu nedenle, YZ geliştirilmiş Elektro-kardiyogramın asemptomatik hastaların kullanılabilir bir araç olarak kullanılıp kullanılmayacağı geniş çapta yaygınlık kazanmıştır. Kwon ve (25) EKG'leri kullanarak orta veya şiddetli aort darlığını tespit etmeyi amaçlayan çok katmanlı bir algılayıcı (MLP) ve CNN'i birleştiren Derin Öğrenme tabanlı bir algoritma geliştirmiştir. Dahili ve harici doğrulama sırasında, önemli aort daralmasını tanımlamak için AUC 0.88 ve 0.86 idi. Duyarlılık analizi göstermiştir ki algoritması AS varlığını belirlemek için prekordiyal derivasyonun T dalgasına odaklanmıştır. İlginç bir şekilde, son derece hassas işlem noktasında, negatif tahmin değeri >%99'du, bu da bu algoritmanın AS'yi dışlamak için bir tarama aracı olarak kullanılabilir. Shelly ve arkadaşları (26) 129.788 yetişkinden EKG ve ekokardiyogram kullanarak orta veya şiddetli AS'yi taramak için bir CNN modeli geliştirmiştir. Hastalar. AI-ECG, 102.926 katılımcıyı içeren test grubunda 0,85 AUC ve %74 doğrulukla iyi performans göstermiş ve negatif tahmin değeri %98,9 olmuştur. Cinsiyet ve yaş modele eklendiğinde, AUC 0,90'a yükselmiştir. Ayrıca, Elias ve ark. (27) tarafından geliştirilen Valve Net DL modeline göre orta veya şiddetli AS, aort yetersizliği (AR) ve mitral yetersizliğini (MR) tespit etmek için EKG

kullanmanın AUC değeri sırasıyla 0,88, 0,77 ve 0,83'tür. Bunlardan herhangi birinin birleşik değerinin AUC'si 0,84'tü. Alt küme analizleri algoritmanın performansının cinsiyet, etnik köken ve ırk açısından eşit olduğunu göstermiştir. Bu çalışmalar AI-ECG'nin kalp kapak hastalığı taraması için potansiyel bir önlemdir.

Atriyal fibrilasyon

Atriyal fibrilasyon (AF), özellikle paroksizmal AF, genellikle asemptomatiktir ve anlaşılması zordur (28). AF'li hastalar EKG kaydı sırasında genellikle normal sinüs ritmi gösterirler, bu da eksik tanıya yol açabilir (29). Ancak AF oluşuktan sonra kalbin yapısı değişmeye başlar. Bu nedenle, normal sinüs ritmi EKG'leri, derinlemesine eğitilmiş bir sinir ağının AF'yi tahmin etmek için tanımlayabileceği ince değişikliklere uğrayabilir (30). Attia ve arkadaşları (30) standart 10 saniyelik, 12 derivasyonlu EKG kullanarak normal sinüs ritmi sırasında AF olan hastaları belirlemek için bir CNN uygulamıştır. Model yaklaşık 500.000 EKG kullanılarak eğitilmiştir. Modelin test setinde uygulanması sonucunda AUC Sinüs ritimli EKG'lerden AF'yi tespit etmek için 0,87 ve genel doğruluk oranı %79,4'tür. Model, hastaların ilgi penceresindeki tüm EKG'ler üzerinde test edildiğinde (İlk kaydedilen AF EKG'sinden 31 gün öncesinden o güne kadar), AUC %88,3'lük genel doğrulukla 0,90'a yükselmiştir. Sonuçlar, bu algoritmanın normal sinüs ritimli EKG'den AF'li hastaları tespit edebildiğini göstermektedir. Daha sonra, Khurshid ve arkadaşları Aging Research in Genomic Epidemiology-Atrial Fibrillation) skorlarının gelecekteki AF riskini öngörmedeki doğruluğunu ve korelasyonunu üç test setinde (Massachusetts Gen-eral Hospital [MGB], Brigham and Women's Hospital [BWH] ve UK Biobank) karşılaştırmıştır. 5 yıllık takip süresi boyunca AI-ECG, AF'yi tahmin etmede CHARGE-AF'ye öngörülse yararlılık sağlamıştır. (MGB, BWH ve UK Biobank'ın AUC değerleri 0,823'e karşı 0,802, 0,747'ye karşı 0,752 ve 0,705'e karşı 0,732 idi). Model hem AI-ECG hem de CHARGE-AF'yi birleştirdiğinde, birden fazla modelde daha iyi performans göstermiştir. CHARGE-AF'ye kıyasla prognostik model ölçümleri, AI-ECG'nin gelecekteki AF riskini değerlendirmek için yararlı bir yol olarak kullanılabilirliğini göstermektedir. Ayrıca AI, risk faktörü tabakalaşmasını değerlendirerek gelecekteki AF'yi de tespit edebilir. Prospektif bir kohort çalışmasında, Noseworthy ve arkadaşları (31) inme risk faktörleri olan ancak sinüs ritminde EKG'si normal olan 1003 hastayı işe almış ve EKG'lerine AI algoritması uygulayarak hastaları yüksek riskli veya düşük riskli gruplara ayırmıştır. Daha sonra tüm katılımcılara 30 gün boyunca AF'yi tespit etmek için ambulatuvar kalp ritmi monitörü verilmiştir. Yüksek riskli grubun düşük riskli gruba göre daha yüksek oranda AF geçirdiğini tespit etmişlerdir (%7,6'ya karşı %1,6). Medyan takip süresi olan 9,9 ay boyunca, AF'nin tespit edilme oranı YZ rehberliğindeki tarama grubunda olağan bakım grubuna kıyasla önemli ölçüde daha yüksekti; bu da YZ EKG'nin gelecekte AF'ye yakalanma riski yüksek olan hastaları belirleyebileceğini düşündürmektedir. Bu hastaların etkili bir şekilde taranması daha etkili sonuçlara yol açabilir. (%7,6'ya karşı %1,6). Medyan takip süresi olan 9,9 ay boyunca, AF'nin tespit edilme oranı YZ rehberliğindeki tarama grubunda olağan bakım grubuna kıyasla önemli ölçüde daha yüksekti; bu da YZ EKG'nin gelecekte AF'ye yakalanma riski yüksek olan hastaları belirleyebileceğini düşündürmektedir. Bu hastaların etkili bir şekilde taranması daha etkili sonuçlara yol açabilir.

Koroner Arter Hastalığı

Betancur ve arkadaşları (32) SPECT miyokardiyal perfüzyon görüntülemesinden (MPI) gelecekteki koroner arter hastalığını (KAH) tahmin etmek için bir Derin öğrenme modeli eğitmeye çalışmıştır. KAH olmayan 1638 hastaya stres SPECT MPI ve MPI'dan sonraki 6 ay içinde invazif koroner anjiyografi uygulanmıştır. Model, tabakalı on katlı çapraz doğrulama yöntemiyle değerlendirilmiştir. KAH öngörüsünün AUC değeri hasta başına 0,80 ve damar başına 0,76 olup DL'nin MPI analizine yardımcı olabileceğini ve gelecekteki KAH'ı öngörebileceğini göstermektedir. Yüz özellikleri bazı hastalıkların artmış riski ile ilişkili olabilir (42). DL, bu yüz özelliklerine göre hastalıkların taranmasını bile sağlar (34,35) Lin ve arkadaşları (34) 5796 hastanın yüz fotoğraflarını kullanarak KAH'ı tespit etmek için bir DL algoritmasını eğitmiş ve doğrulamıştır. DL algoritması, 1013 hastadan oluşan test setinde 0,73 AUC değerine ve KAH'ı tespit etmek için %68 doğruluğa sahiptir.

Kalp Yetmezliği

Sol ventrikül sistolik fonksiyonunun önemli bir ölçüsü olan sol ventrikül ejeksiyon fraksiyonu (LVEF) genellikle ekokardiyografi ile ölçülür (36). Kalp yetersizliğinin (KY) erken evresinde, hastalar LVEF'deki hafif düşüş nedeniyle uzun süre asemptomatik sol ventrikül disfonksiyonu (ALVD) gösterebilir (37,38) KY hastaları etkili bir tedavi alabilirse, sol ventrikül sistolik fonksiyonlarını iyileştirmek, LVEF'nindaha da düşmesini ve kalıcı miyokardiyal hasarı önlemek ve sağ kalım oranını ve yaşam kalitesini iyileştirmek çok önemlidir (39). Ancak eko kardiyografi, maliyet ve ulaşılabilirlik nedeniyle asemptomatik hastalar için pratik değildir (38,36). Son zamanlarda, çeşitli çalışmalar AI-EKG'nin ALVD taraması için kullanılabileceğini göstermiştir. Attia ve arkadaşları (3) 44,959 hastanın EKG ve ekokardiyogramını kullanarak büyük bir sinir ağı oluşturmuşlardır.

Konjenital Kalp Hastalıkları

Konjenital kalp hastalığı (KKH) en yaygın konjenital sakatlıktır ve doğumdan sonra önemli ölçüde ölümlerle sonuçlanır (40). Klinik uygulamada, uzman sonografların eksikliği veya KKH tanısına yardımcı olacak kritik görüntü karelerinin eksik olması nedeniyle, hamilelik sırasında KKH'nin tespiti genellikle çok düşüktür (41). AI-EKG olarak, eğitilmiş AI modelleri, klinisyenin ayırt etmesi zor olan anormal görüntü karelerini tespit edebilir ve KKH'nin teşhisini iyileştirebilir (42). Yakın zamanda, Arnaout ve arkadaşları (42) 18 ila 24 haftalık ekokardiyografik ve tarama ultrasonundan yaklaşık 100,000 görüntü kullanarak normal kalpleri ve KKH'yi ayırt etmek için bir sinir ağını eğitmiştir. Dahili test setinde, model normalden anormalden ayırt etmiştir.

SONUÇ

YZ, performansı, hassasiyeti ve zaman verimliliğini artırmanın yanı sıra maliyeti düşürmek için birçok sektörde hızla benimsenen bir teknolojidir. Tıpta bu teknoloji, daha erken tespit ve teşhis, iyileştirilmiş teşhis ve tedavi protokolleri, böylece olası tıbbi hataların azaltılması, tıbbi maliyetlerin düşürülmesi ve morbidite ve mortalitenin azaltılması yoluyla iyileştirilmiş hasta bakımına katkıda bulunacağı düşünülmektedir.

YZ kullanımında amaç hekimlerin yerini almak için değil de, tıbbi süreçlere destek olmaktır. YZ sağlık alanında çalışan insan gücüne destek olacağı ve çalışanların performansını arttıracacağı düşünülmektedir. Özellikle kalp hastalıklarının teşhisinde kullanılan görüntüleme ve sinyal işleme sistemleri ile eş güdümlü olarak kullanılacak olan YZ bu alana büyük katkı sunacaktır.

AÇIKLAMALAR

Finansal destek yoktur.

Çıkar çatışması yoktur.

KAYNAKLAR

1. Clark H. Ncds: a challenge to sustainable human development. The Lancet 2013; 381: 510–1. doi: [https://doi.org/10.1016/S0140-6736\(13\)60058](https://doi.org/10.1016/S0140-6736(13)60058)
2. Krittanawong, C., Zhang, H., Wang, Z., Aydar, M., & Kitai, T. (2017). Artificial intelligence in precision cardiovascular medicine. Journal of the American College of Cardiology, 69(21), 2657-2664.
3. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review. 1958; 65: 386–408.
4. Koza JR, Bennett FH, Andre D, Keane MA. Automated Design of both the Topology and Sizing of Analog Electrical Circuits Using Genetic Programming. Artificial Intelligence in Design '96. 1996; 7: 151–170.
5. Brownlee J. 4 Types of Classification Tasks in Machine Learning. Machine Learning Mastery. 2021. Available at: <https://machinelearningmastery.com/types-of-classification-in-machine-learning/> (Accessed: 23 July 2021).
6. Romiti S, Vinciguerra M, Saade W, Anso Cortajarena I, Greco E. Artificial Intelligence (AI) and Cardiovascular Diseases: an Unexpected Alliance. Cardiology Research and Practice. 2020; 2020: 1–8.
7. Zghyer F, Yadav S, Elshazly MB. Artificial Intelligence and Machine Learning. Precision Medicine in Cardiovascular Disease Prevention. 2021; 18: 133–148.

8. Litjens G, Ciompi F, Wolterink JM, de Vos BD, Leiner T, Teuwen J, et al. State-Of-The-Art deep learning in cardiovascular image analysis. *JACC Cardiovasc Imaging* 2019; 12(8 Pt 1): 1549–65. doi: <https://doi.org/10.1016/j.jcmg.2019.06.009>
9. Mazurowski MA, Buda M, Saha A, Bashir MR. Deep learning in radiology: an overview of the concepts and a survey of the state of the art with focus on MRI. *J Magn Reson Imaging* 2019; 49: 939–54. doi: <https://doi.org/10.1002/jmri.26534>
10. Hochreiter S, Schmidhuber J. Long shortterm memory. *Neural Comput* 1997; 9: 1735–80. doi: <https://doi.org/10.1162/neco.1997.9.8.1735>
11. Bai W, Suzuki H, Qin C, Tarroni G, Oktay O, Matthews PM. Recurrent neural networks for aortic image sequence segmentation with sparse annotations. *arXiv e-prints [serial on the Internet]*. 2018. Available from: <https://ui.adsabs.harvard.edu/abs/2018arXiv180800273B>
12. Qin C, Schlemper J, Caballero J, Price AN, Hajnal JV, Rueckert D. Convolutional recurrent neural networks for dynamic Mr image reconstruction. *IEEE Trans Med Imaging* 2019; 38: 280–90. doi: <https://doi.org/10.1109/TMI.2018.2863670>
13. Xu C, Xu L, Gao Z, Zhao S, Zhang H, Zhang Yet al. Direct Detection of PixelLevel Myocardial Infarction Areas via a Deep-Learning Algorithm. Cham: Springer International Publishing; 2017.
14. Guo Z, Bai J, Lu Y, Wang X, Cao K, Song Qet al. DeepCenterline: A Multi-task Fully Convolutional Network for Centerline Extraction. Cham: Springer International Publishing; 2019.
15. Dey D, Slomka PJ, Leeson P, Comaniciu D, Shrestha S, Sengupta PP, et al. Artificial intelligence in cardiovascular imaging: JACC state-of-the-art review. *J Am Coll Cardiol* 2019; 73: 1317–35. doi: <https://doi.org/10.1016/j.jacc.2018.12.054>
16. Petersen SE, Matthews PM, Bamberg F, Bluemke DA, Francis JM, Friedrich MG, et al. Imaging in population science: cardiovascular magnetic resonance in 100,000 participants of UK Biobank - rationale, challenges and approaches. *J Cardiovasc Magn Reson* 2013; 15. doi: <https://doi.org/10.1186/1532-429X-15-46>
17. Coffey S, Lewandowski AJ, Garratt S, Meijer R, Lynum S, Bedi R, et al. Protocol and quality assurance for carotid imaging in 100,000 participants of UK Biobank: development and assessment. *Eur J Prev Cardiol* 2017; 24: 1799–806. doi: <https://doi.org/10.1177/2047487317732273>
18. Aye CYL, Lewandowski AJ, Lamata P, Upton R, Davis E, Ohuma EO, et al. Disproportionate cardiac hypertrophy during early postnatal development in infants born preterm. *Pediatr Res* 2017; 82: 36–46. doi: <https://doi.org/10.1038/pr.2017.9>
19. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *The Journal of the American Medical Association*. 2016; 316: 2402.
20. Ski CF, Thompson DR, Brunner-La Rocca H. Putting AI at the centre of heart failure care. *ESC Heart Failure*. 2020; 7: 3257–3258.
21. Yan Y, Zhang JW, Zang GY, Pu J. The primary use of artificial intelligence in cardiovascular diseases: what kind of potential role does artificial intelligence play in future medicine? *Journal of Geriatric Cardiology*. 2019; 16: 585–591.
22. Dawes TJW, de Marvao A, Shi W, Fletcher T, Watson GMJ, Wharton J, et al. Machine Learning of Three-dimensional Right Ventricular Motion Enables Outcome Prediction in Pulmonary Hypertension: a Cardiac MR Imaging Study. *Radiology*. 2017; 283: 381–390.
23. Lancellotti P, Magne J, Dulgheru R, Clavel M-A, Donal E, Vannan MA, et al. Outcomes of patients with asymptomatic aortic stenosis followed up in heart valve clinics. *JAMA Cardiol*. 2018;3(11):1060–8.
24. Leon MB, Smith CR, Mack M, Miller DC, Moses JW, Svensson LG, et al. Transcatheter aortic-valve implantation for aortic stenosis in patients who cannot undergo surgery. *N Engl J Med*. 2010;363(17):1597–607.
25. Kwon JM, Lee SY, Jeon KH, Lee Y, Kim KH, Park J, et al. Deep learning based algorithm for detecting aortic stenosis using electrocardiography. *J Am Heart Assoc*. 2020;9(7):e014717.
26. Cohen-Shelly M, Attia ZI, Friedman PA, Ito S, Essayagh BA, Ko W-Y, et al. Electrocardiogram screening for aortic valve stenosis using artificial intelligence. *Eur Heart J*. 2021;42(30):2885–96.
27. Elias P, Poterucha TJ, Rajaram V, Moller LM, Rodriguez V, Bhave S, et al. Deep learning electrocardiographic analysis for detection of left-sided valvular heart disease. *J Am Coll Cardiol*. 2022;80(6):613–26.
28. Siontis KC, Gersh BJ, Killian JM, Noseworthy PA, McCabe P, Weston SA, et al. Typical, atypical, and asymptomatic presentations of new-onset atrial fibrillation in the community: characteristics and prognostic implications. *Heart Rhythm*. 2016;13(7):1418–24.
29. Davidson KW, Barry MJ, Mangione CM, Cabana M, Caughey AB, Davis EM, et al. Screening for atrial fibrillation: US preventive services task force recommendation statement. *JAMA*. 2022;327(4):360–7

30. Attia ZI, Noseworthy PA, Lopez-Jimenez F, Asirvatham SJ, Deshmukh AJ, Gersh BJ, 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(10201):861–7.
31. Noseworthy PA, Attia ZI, Behnken EM, Giblon RE, Bews KA, Liu S, et al. Artificial intelligence-guided screening for atrial fibrillation using electrocardiogram during sinus rhythm: a prospective non-randomised interventional trial. *Lancet*. 2022;400(10359):1206–12.
32. Betancur J, Commandeur F, Motlagh M, Sharir T, Einstein AJ, Bokhari S, et al. Deep learning for prediction of obstructive disease from fast myocardial perfusion SPECT: a multicenter study. *JACC Cardiovasc Imaging*. 2018;11(11):1654–63.
33. Christofersen M, Tybjaerg-Hansen A. Visible aging signs as risk markers for ischemic heart disease: epidemiology, pathogenesis and clinical implications. *Ageing Res Rev*. 2016;25:24–41.
34. Lin S, Li Z, Fu B, Chen S, Li X, Wang Y, et al. Feasibility of using deep learning to detect coronary artery disease based on facial photo. *Eur Heart J*. 2020;41(46):4400–11.
35. Yan BP, Lai WHS, Chan CKY, Au ACK, Freedman B, Poh YC, et al. Highthroughput, contact-free detection of atrial fibrillation from video with deep learning. *JAMA Cardiol*. 2020;5(1):105–7.
36. Vaid A, Johnson KW, Badgeley MA, Somani SS, Bicak M, Landi I, et al. Using deep-learning algorithms to simultaneously identify right and left ventricular dysfunction from the electrocardiogram. *JACC Cardiovasc Imaging*. 2022;15(3):395–410.
37. Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, et al. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med*. 2019;25(1):70–4.
38. Yao X, Rushlow DR, Inselman JW, McCoy RG, Thacher TD, Behnken EM, et al. Artificial intelligence-enabled electrocardiograms for identification of patients with low ejection fraction: a pragmatic, randomized clinical trial. *Nat Med*. 2021;27(5):815–9.
39. de Couto G, Ouzounian M, Liu PP. Early detection of myocardial dysfunction and heart failure. *Nat Rev Cardiol*. 2010;7(6):334–44.
40. Donofrio MT, Moon-Grady AJ, Hornberger LK, Copel JA, Sklansky MS, Abuhamad A, et al. Diagnosis and treatment of fetal cardiac disease: a scientific statement from the American heart association. *Circulation*. 2014;129(21):2183–242.
41. Sun HY, Proudfoot JA, McCandless RT. Prenatal detection of critical cardiac outflow tract anomalies remains suboptimal despite revised obstetrical imaging guidelines. *Congenit Heart Dis*. 2018;13(5):748–56.
42. Arnaout R, Curran L, Zhao Y, Levine JC, Chinn E, Moon-Grady AJ. An ensemble of neural networks provides expert-level prenatal detection of complex congenital heart disease. *Nat Med*. 2021;27(5):882–91.