

## Kardiyovasküler Hastalıkların Tanı ve Tedavisinde Yapay Zeka Kullanımı

Mehmet Semih Belpınar<sup>1</sup>

### Özet

Yapay zekanın (YZ) kardiyolojide kullanımı, tıbbın diğer alanlarında olduğu gibi son yıllarda muazzam bir artış göstermiştir. YZ, teşhis, tedavi planlaması, risk değerlendirmesi ve hastalık yönetimi gibi kardiyoloji uygulamalarının birçok alanında önemli bir potansiyel sunmaktadır. Bu bölüm kardiyovasküler hastalıkların tanı ve tedavisinde YZ kullanımı konusunda güncel durumu incelemeyi amaçlamaktadır. Ayrıca bilgisayar bilimleri konusunda sınırlı uzmanlığa sahip klinisyenlerin konunun sınırlarını daha iyi anlamalarına ve YZ algoritmalarını klinik uygulamaya koymalarına olanak tanıyabilecek kardiyovasküler hastalıklarda YZ'nin mevcut uygulamalarını tanıtmaktır.

### 1. Giriş

#### 1.1. Yapay zeka ve tıp alanında kullanımı

Bilgisayar biliminin bir dalı olarak yapay zeka (YZ), karmaşık sorunlarla başa çıkmak için insan zekasını simüle eden ve genişleten yeni bir teknik bilimdir (1). Gelişmiş bilgisayar algoritmaları kullanarak karmaşık veri tabanlarından bilgi çıkarma tekniği olan YZ, tıp alanına da son yıllarda hızlıca girmiştir (2). YZ, verileri işlemek için insan beynini taklit eder ve tıpta önemli bir rol oynar; sağlık verilerinin (medikal kayıtlar, ilaçlar ve deneysel sonuçlar, vb.) büyük miktarda tanımlanması, işlenmesi, entegrasyonu ve analizini yapabilir (3). YZ, verilerden manuel kodlama yerine gizli bağlantıları keşfederek hastalık tahmini, tanı, prognoz ve iyileşme süreçlerini devrim niteliğinde dönüştürme potansiyeline sahiptir (4).

YZ'nin alt disiplinleri arasında bilişsel hesaplama, derin öğrenme (DL) ve makine öğrenimi (ML) yer alır (5). ML, denetimli, denetimsiz ve pekiştirmeli

1 Sivas Numune Hastanesi-Kardiyoloji Kliniği, Email: mehmetsemihbelpinar@gmail.com  
Orcid Id: <https://orcid.org/0000-0002-6768-3710>

öğrenme olmak üzere üçe ayrılır ve her biri eğitim sırasında farklı denetim düzeylerine sahiptir (6). Denetimli öğrenme, sınıf örnekleri kullanarak sınıflandırıcıların performansını optimize ederken, denetimsiz öğrenme, etiketlenmemiş verileri analiz ederek desenler keşfeder (7). Pekiştirmeli öğrenme ise hem denetimli hem de denetimsiz yaklaşımları birleştirerek deneme-yanılma yoluyla algoritma doğruluğunu artırır (8).

Klinik tıp, demografik veriler, semptom özellikleri, elektrokardiyogram bulguları, laboratuvar değerleri, biyomarker seviyeleri ve görüntüleme çalışmaları gibi çeşitli hasta verilerinin entegrasyonunu gerektirir. Optimal tedavi yönetimi, planlanan tedavinin uygun, faydalı olduğuna ve zararsız veya çok az zarara yol açacağına dair yüksek bir olasılığa dayanmalıdır. Bu doğrultuda, kişiselleştirilmiş risk-fayda değerlendirmeleri, bireysel hasta yönetimini yönlendirmelidir. Ancak, mevcut devasa veri büyüklüğü nedeniyle bu temel klinik görevler giderek daha zor hale gelmiştir (9).

Bir kez doğrulanan ve test edilen algoritmalar klinikte kullanılmaya başlandığında, ön tanı sunarak, klinik hata düzeltmeleri yaparak ve yanlış tanıların oluşumunu engelleyerek kliniklerin bilişsel yükünü azaltabilir (10).

YZ/ML, klinik uzmanlara hasta geçmişlerini elde etme ve kapsamlı bir şekilde hazırlama, yüz ve ses gibi klinik özellikleri analiz etme, laboratuvar sonuçları, biyomarkerler ve görüntülemeleri entegrasyon sağlama gibi konularda yardımcı olabilir. Ayrıca, YZ/ML, optimal akut ve kronik bakım için kapsamlı bir risk değerlendirmesi sunabilir. YZ/ML algoritmalarının klinik kullanımdan önce dikkatle değerlendirilmesi, doğrulama veri setleriyle geçerliliğinin onaylanması ve hasta fenotipleri değiştiğinde tekrar tekrar yeniden değerlendirilmesi gerekir (9).

## **1.2. Kardiyovasküler hastalıklarda yapay zeka uygulamaları**

Kardiyovasküler hastalıklar, dünya genelinde önde gelen ölüm nedenidir ve sağlık harcamalarına önemli bir katkı sağlar. Kardiyoloji, kalp ve damar sistemiyle ilgili hastalıkların tanı, tedavi ve yönetimi ile ilgilenen bir tıp dalıdır. Bu alan, kalp hastalıkları, damar hastalıkları, hipertansiyon, kalp yetmezliği, kalp krizi, ritim bozuklukları ve doğumsal kalp hastalıkları gibi pek çok konuyu kapsar. Kardiyologlar, kalp ve damar sağlığıyla ilgili çeşitli hastalıkları teşhis eder, tedavi eder ve önleyici tedbirler alır (11,12). Kardiyoloji ve tüm alt branşları, çeşitli hastalıklar için yeni tedavi stratejileri geliştirmede sınırları zorlamaya devam etmektedir (11).

Kardiyoloji, YZ sayesinde geleneksel algoritmalara göre daha etkili hale gelebilir (13). Geleneksel yöntemler, bazı varsayımlar gerektirir ve bu varsayımlar her zaman gerçek dünyadaki görevlerle uyumlu olmayabilir,

bu da modelin başarısını kısıtlayabilir. ML ise daha az varsayım yaparak genellikle daha doğru tahminler ve sınıflandırmalar yapar. Bu özellikleri, YZ ve ML'in kardiyovasküler tıpta önemli avantajlar sunmasını sağlar (13, 14). YZ, büyük veri kümelerini analiz ederek karmaşık ilişkileri çözme, yeni patofizyolojik durumları keşfetme ve tahminsel modeller geliştirme yeteneğine sahiptir. Kardiyovasküler tıpta, ML ve DL gibi araçlar, hastalık haritalama, erken uyarı sistemleri, risk tahminleri ve görüntülerin otomatik işlenmesi gibi alanlarda üstün etkinlik göstermektedir. Bu teknolojiler, operasyonel verimliliği artırırken, kişiselleştirilmiş bakım ve karar destek sistemlerini iyileştirmede de büyük potansiyel sunmaktadır (13, 14).

YZ algoritmaları, büyük veri analizleriyle klinik tanıyı iyileştirir. Örneğin, YZ destekli ekokardiyogramlar (EKG); kalp yetmezliği, atriyal fibrilasyon, anemi, hipertrofik kardiyomiopati ve pulmoner hipertansiyon gibi hastalıkların tanısında kullanılır. YZ, kardiyovasküler hastalıkların tanı ve tedavisini hızlandırma potansiyeline sahiptir (2). Klinik senaryoda, YZ'nin kardiyovasküler hastalıkların teşhisinde iyi bir şekilde uygulandığı, yardımcı araçların etkinliğini artırdığı, hastalık tabakalaşması ve tiplendirmesi ve sonuç tahmininde bulunduğu kanıtlanmıştır. Büyük miktarlardaki sağlık verilerinden ince bağlantıları yakalamak için derinlemesine geliştirilen yeni YZ algoritmalarının, geleneksel yöntemlerden daha karmaşık görevlerin üstesinden gelmesi beklenmektedir (2).

Günlük klinik pratiğe bakıldığında, KVH'ların tanı ve tedavisi, çeşitli formatlarda elde edilen verilere dayanır. Bu formatlar; hasta öyküsü, fiziksel muayene, laboratuvar verileri, non-invaziv görüntüleme testleri ve invaziv anjiyografi gibi bilgileri içerir. Mobil telemetri cihazları, giyilebilir ve implant edilebilir kayıt cihazları, elektronik sağlık kayıtlarındaki biyometrikler, araştırma verileri ve hasta tarafından üretilen sağlık verileri gibi yeni veri zengini teknolojilerin kullanılması, kardiyologlardan giderek daha karmaşık analizler yapmalarını gerektirmektedir (15-18). Kardiyovasküler tıp, diğer branşlar gibi, üçlü hedefi başarıma baskısıyla karşı karşıyadır: hasta bakımını optimize etmek, maliyetleri düşürmek ve sonuçları iyileştirmek. Bu seviyede hassas bakım için gereken veri hacmi oldukça büyüktür ve etkili bir şekilde kullanılabilmesi için hızlı bir şekilde değişmektedir; bu nedenle sağlam bir klinik karar destek aracının yardımı olmadan kullanılması zordur (15). Krittanawong ve arkadaşları, bilişsel hesaplama olmadan, aşırı kullanım ve yetersiz hasta bakımı nedeniyle bu branşın, yeniden hastaneye yatış ve ölüm oranlarını etkileyen pratik zorluklarla karşılaştığını öne sürmektedir (19). Klinik karar verme, veri aşırı yükü ve bakımın iyileştirilmesi, tıbbi ilerlemelerin ve bilgilerin uygulanabilir bir plana dönüştürülmesi baskısıyla zor bir süreçtir. YZ araçları, özellikle ML araçları, klinisyenin etkinliğini

potansiyel olarak artırma ve geliştirme konusunda önemli bir rol oynayarak hasta bakımını devrim niteliğinde değiştirme potansiyeline sahiptir (15).

### **1.2.1. Yapay zekanın kardiyak görüntüleme kullanım alanları**

YZ ve özellikle ML kullanmanın kardiyolojideki etkinliği, koroner arter hastalığı risk tahmini gibi çeşitli alanlarda ve kardiyak görüntüleme uygulamalarında da kanıtlanmıştır (15).

YZ, EKG analizi gibi kardiyovasküler patoloji tanısında önemli bir yer tutmaktadır. 1996'dan bu yana, YZ kullanımı sürekli olarak gelişmiştir (21). EKG analizi, ML yöntemlerinin kardiyolojideki en ileri uygulamalarından biridir ve kamuya açık veritabanlarıyla desteklenmiştir (22). YZ, EKG'yi yorumlamak, kalp ritimlerini otomatik olarak tanımlamak, EKG'yi biyometrik olarak kullanarak bireyi tanımlamak ve yüzey EKG'sinden kalp hastalıklarını tespit etmek için uygulanmaktadır. EKG, kalp yapısını zamanında ve maliyet etkin bir şekilde değerlendirirken, erişilebilirlik, kalite ve tanınabilirlik konusunda farklılıklar göstermektedir. Yorumlama, operatör deneyimine bağlıdır ve YZ, bu süreci iyileştirme ve standardize etme fırsatları sunmaktadır. Konvolüsyonel sinir ağlarıyla yapılan görüntü sınıflandırma araştırmaları ilgi yaratmış, EKG verilerinin büyük hacmi de YZ platformlarının gelişmesi için fırsatlar sunmuştur. YZ, otomatik kantifikasyon ve patolojik özelliklerin tanımlanmasıyla yorumlama ve iş akışını iyileştirebilir, ayrıca subklinik hastalıkları ve prognozu belirleyebilecek ince özellikleri tanımlamada güçlüdür (22-30).

Birçok çalışma, sol ventriküler hipertrofi (LVH) tanımlamak için bir yaklaşım oluşturmak üzere ek klinik ve laboratuvar verileri ile veya bunlar olmadan EKG'yi değerlendirmek için ML modelleri önermiştir (22-30). Modern ML modelleri, EKG'deki QRS kompleksleri ve P/T dalgalarını yüksek doğrulukla tanımlar, böylece kalp hızı (HR) gibi klinik parametreler hesaplanabilir (23). DL sistemleri, EKG analizini güçlendirerek aritmileri ve atriyal fibrilasyonu (AFib) tespit eder (24). ML, insan yorumuna olan bağımlılığı azaltabilir ve aynı zamanda EKG'nin tanınabilirliğini artırabilir. ML algoritmaları, büyük miktarda veriyi hızlı bir şekilde analiz edebilir ve gizli desenleri veya anormallikleri tespit edebilir, bu da klinik karar destek sistemlerine katkı sağlar. Böylece, insan hatasını azaltırken daha hassas ve güvenilir sonuçlar elde edilebilir (25-27). Güncel bir çalışmada, sol ventrikül hipertrofisini (LVH) sınıflandırmak için ML yöntemlerini kullanmıştır. EKG verilerinden çıkarılan özelliklerle LGBM, MLP ve ResNet gibi modellerin, geleneksel kriterlere ve tek bir EKG değişkenine göre daha yüksek doğruluk sağladığı bulunmuştur. Ayrıca, LGBM modelinin yanlış

pozitifleri, LVH gelişimi açısından daha yüksek risk taşımaktadır. Sonuç olarak, ML modelleri, LVH sınıflandırma ve gelecekteki LVH tahminlerinde geleneksel yöntemlere üstün olmuştur (25). Ayrıca, ML, giyilebilir cihazlarda derin sinir ağları (DNN) kullanılarak EKG analizi için %99 doğruluk oranı sağlanmıştır (24). Ancak sinir ağı olmayan ML modelleri (lojistik regresyon, rastgele orman, vb.) yüksek boyutlu EKG sinyallerini doğrudan işleyemez ve yalnızca çıkarılmış özelliklerle sınırlıdır, bu da bazı tanısal bilgilerin kaybolmasına yol açabilir. Sinir ağları ise bu bilgileri doğrudan öğrenebilir ve daha yüksek doğruluk sağlar (28).

Dwivedi ve arkadaşlarının çalışmasında (29), LVH tespiti için yalnızca uzuv elektrotlarından (limb lead) elde edilen 6-derivasyonlu EKG'ler üzerinden makine öğrenimi modelleri değerlendirilmiştir. Çalışmanın amacı, farklı makine öğrenimi modellerinin performansını karşılaştırarak, LVH'nin erken tespiti için etkili bir yöntem geliştirmektir. Sonuç olarak, yalnızca limb lead'leri kullanarak yapılan analizlerin, klinik açıdan erken teşhis için değerli olduğu ve mobil EKG cihazlarında LVH tespiti için potansiyel sunduğu bulunmuştur (29). Khurshid ve arkadaşlarının çalışmasında (30), 12-derivasyonlu EKG'ler kullanarak kardiyak manyetik rezonans (CMR) türevi sol ventriküler kütle (LV mass) tahmin etmek için derin öğrenme modelleri geliştirilmiştir. Çalışmanın amacı, derin öğrenme ile LVH tespiti ve CMR türevi LV kütesinin tahmin edilmesinde geleneksel EKG kurallarına kıyasla daha iyi sonuçlar elde etmektir. Sonuçlar, derin öğrenme modelinin CMR türevi LV kütesiyile güçlü bir korelasyon gösterdiğini ve LVH tespitinde geleneksel EKG kurallarına göre daha üstün ayırım gücü sunduğunu ortaya koymuştur. Ayrıca, modelin LVH tahminlerinin kardiyovasküler olaylarla ilişkili olduğu bulunmuştur (30).

Rjoob ve arkadaşlarının meta-analizine (31) 14 çalışma dahil edilmiştir. Çalışma, 12-derivasyonlu EKG kaydında elektrot yerleşim hatalarının tespiti için makine öğrenimi (ML) tekniklerini incelemiştir. Elektrot yerleşim hatalarının EKG morfolojisi ve hastalık teşhisleri üzerindeki etkilerini araştıran bu meta-analiz, ML algoritmalarının yüksek duyarlılıkla hataları tespit ettiğini, ancak sol kol/sol bacak değişikliği gibi bazı yerleşim hatalarını tespit etmekte zorluk yaşandığını ortaya koymuştur. Sonuçlar, konvolüsyonel sinir ağları (CNN) gibi derin öğrenme tekniklerinin, elektrot yerleşim hatalarının tespiti için umut verici bir potansiyele sahip olduğunu göstermektedir (31).

Cai ve arkadaşlarının çalışmasında (32), LVH tespiti için iki boyutlu (2D) konvolüsyonel sinir ağı (CNN) tabanlı bir yöntem önerilmiştir. 42,127 EKG-ekokardiyografi verisi kullanılarak, tekli görüntüler oluşturulmuş ve

lead seçimi yapılmıştır. 2D-CNN modeli, LVH tespitinde 0.916 AUROC değeriyle geleneksel EKG kriterlerinden ve diğer makine öğrenimi yöntemlerinden (lojistik regresyon, rastgele orman) daha iyi performans göstermiştir. Bu yöntem, sınırlı hesaplama kaynaklarıyla uyumlu olup, erken tanı ve hasta sonuçlarını iyileştirme potansiyeline sahip olduğu bildirilmiştir (32).

Rabkin'in derleme çalışmasında (33), LVH tespiti için kullanılan ML algoritmalarının çeşitli özellikleri sistematik olarak incelenmiştir. Çalışmanın amacı, LVH tespitinde kullanılan ML algoritmalarını klasik EKG kriterleriyle karşılaştırmak ve bu algoritmaların duyarlılık, özgüllük, doğruluk gibi test performanslarını değerlendirmektir. Çalışma, 14 farklı araştırmayı ele almış ve çeşitli ML algoritmalarının kullanıldığını (destek vektör makineleri, lojistik regresyon, Random Forest, derin sinir ağları vb.) göstermiştir. Sonuçlar, ML algoritmalarının genellikle klasik EKG kriterlerine göre daha yüksek duyarlılık sağladığını, ancak özgüllük açısından eşit veya daha düşük performans gösterdiğini ortaya koymuştur. Çalışma, ML algoritmalarının klinik uygulamalarda kullanımını zorlaştıran karmaşık veri setlerine ihtiyaç duyduğunu vurgulamaktadır (33).

Kardiyak görüntüleme, DL sistemleri ve özellikle CNN'ler ile büyük bir potansiyel göstermektedir. CNN ve diğer yöntemler, koroner kalsiyum tespiti, trombus hacmi karakterizasyonu, sol atriyum segmentasyonu gibi birçok alanda kullanılmaktadır. Kardiyak görüntülemede tanısal destek, anatomik referans noktalarının segmentasyonunu kullanır. Derin pekiştirmeli öğrenme (deep reinforcement learning) ile model, bilgisayarlı tomografi (BT) görüntüleri içinde hızla anatomik noktaları bulmak için eğitilir (34). Bu yöntem, kalp kapakçıkları modellemesi ve implant boyutlandırması gibi uygulamalar için faydalı olabilir (35). Dey ve arkadaşlarının derleme çalışmasında (35), YZ kardiyovasküler görüntülemede potansiyel etkileri ele alınmıştır. YZ'nin, görüntü segmentasyonu, otomatik ölçümler ve tanıda verimliliği artırarak zamanlama sorunlarını ve eksik tanıları azaltabileceği, ayrıca büyük veriyle birleşerek hastalıkları daha iyi tanımlayıp tedaviyi kişiselleştirebileceğini vurgulanmıştır (35).

Koroner BT anjiyografi (CCTA), koroner arter hastalığının (CAD) non-invaziv değerlendirilmesinde önemli bir rol oynamaktadır. Bilgisayarlı tomografi (BT) ve CCTA, koroner arter anatomisini detaylı şekilde sunarak klinik uygulamalarda önemli bir yer tutar (36). Motwani ve arkadaşları (37), ML algoritmalarının 5 yıllık mortaliteyi tahmin etmede geleneksel ölçütlere göre ROC analizinde daha yüksek bir eğri altı değeri sağladığını bulmuştur. Baskaran ve arkadaşları (38), ML kullanarak kardiyak yapıların

otomatik segmentasyonunda 0.932'lik bir Dice skoru elde ederken, Han ve ekibi (39) ML algoritmalarının, koroner plak ilerlemesini tahmin etmede geleneksel modellerden üstün performans gösterdiğini ortaya koymuştur. Bu çalışmalar, ML algoritmalarının klinik tanı ve değerlendirmede yeni fırsatlar sunduğunu göstermektedir. CCTA, %99'a kadar negatif prediktif değerle tıkaçıcı CAD'yi etkili bir şekilde dışlayabilir ve arteriosklerotik plakların özelliklerini, düşük atenuasyon, pozitif remodelasyon, lekeli kalsifikasyon ve halka işareti gibi yüksek riskli plak belirteçlerini belirleyebilir (40). Ancak bu ölçümler, deneyimli bir gözlemci tarafından karmaşık post-prosesleme gerektirir. Bu nedenle, derin öğrenme, CCTA verilerinden çıkarılan bilgilerin optimize edilmesinde kullanılmakta, özellikle plak analizini otomatik, doğru ve objektif bir şekilde yapabilen algoritmalar geliştirilmiştir (41). Zreik ve arkadaşları (42), 163 hasta üzerinde recurrent CNN kullanarak koroner arter plağını otomatik olarak tespit edip sınıflandırmış ve koroner arter stenozunun derecesini tanılamıştır. Yapılan bu çalışmalarda, otomatik segmentasyon ve stenoz ölçümü ile klinik karar destek sistemlerinin doğruluğunu artırma potansiyeli ortaya konmuştur (42).

Çoğu kardiyovasküler görüntüleme tanısı, kalp boşluklarının, kapaklarının ve koroner arterlerin anatomik segmentasyonuna ve kardiyak fonksiyon parametrelerinin doğru ölçümlerine dayanır. CMR görüntüleme, iyonlaştırıcı radyasyon kullanmadan yüksek kaliteli görüntüler sağlar ve iyi doku kontrastı sunar. CMR, belirli anatomik düzlemleri yakalayabilir ve birçok görüntüleme yöntemini destekler. CMR üzerinde DL ve ML teknikleri, kalp odacıklarının hızlı ve otomatik segmentasyonu ile fonksiyon analizini mümkün kılmaktadır (41). Tao ve arkadaşları (43), 400 cine CMR hastasında yapılan çok merkezli bir çalışmada, otomatik analiz ile manuel uzman analizleri arasında mükemmel bir korelasyon ( $r = 0.98$ ) bulmuşlardır. Ruijsink ve arkadaşları (44) ise 2029 hastada yapılan derin öğrenme tabanlı otomatik kardiyak analizde, manuel analizle yüksek derecede korelasyon ( $r = 0.89-0.95$ ) ve %95 duyarlılık sağlamıştır. Bu sonuçlar, klinik gözetim olmadan kalite kontrollü, tamamen otomatik CMR analizinin uygulanabileceğini göstermektedir (43,44). Baefler ve arkadaşlarının çalışmasında (45), hipertrofik kardiyomiopati (HCM) hastalarında, kontrastsız T1-ağırlıklı CMR görüntülerinde miyokardiyal doku değişikliklerini tespit etmek için ML tabanlı yaklaşımlar kullanılmıştır. Çalışmada, HCM hastaları ve sağlıklı kontrol grubu üzerinde doku analizi (TA) gerçekleştirilmiştir. Çalışmada, ML teknikleri kullanılarak, doku özelliklerini ayırt edebilmek için boyut indirgeme ve özellik seçimi yapılmıştır. Özellikle, **GLvNonU** parametresi, HCM hastalarını sağlıklı kontrollerden ayırt etmek için %91 duyarlılık ve %93 özgüllükle en iyi



sonuçları vermiştir. Ayrıca, bu parametre, geç gadolinyum görüntülenmesi (LGE) olmayan hastalarda bile yüksek doğrulukla ayırt edebilmiştir. Bu çalışma, ML ve TA kullanarak kontrastsız T1-ağırlıklı CMR görüntülerinde HCM'yi tespit etmede yeni bir yaklaşım sunduğunu göstermektedir (45). Alis ve arkadaşlarının çalışmasında (46), HCM hastalarında ventriküler taşiaritmi (VT) varlığını değerlendirmek için geç gadolinyum-enhansman (LGE) CMR görüntülerinde ML tabanlı doku analizi kullanılmıştır. Çalışma, 64 HCM hastası üzerinde gerçekleştirilmiştir ve hastalar 24 saatlik Holter izlemeyi bir yıl içinde CMR ile yapmıştır. Doku analizinde, LGE görüntülerinde yüksek ve orta sinyal yoğunluğuna sahip bölgelerde niteliksel özellikler çıkarılmış ve ML sınıflandırıcıları (destek vektör makineleri, Naive Bayes, k-en yakın komşular ve rastgele orman) kullanılarak VT'nin varlığı tahmin edilmiştir. k-en yakın komşular algoritması, SMOTE ile birlikte kullanıldığında en iyi tanılabilirliği elde etmiştir ve VT pozitif hastaların %95.2'sini doğru şekilde tanımlamıştır. Bu çalışma, LGE görüntülerinde ML tabanlı doku analizinin, HCM hastalarında VT varlığını sınıflandırmada umut verici bir araç olduğunu göstermektedir.

### **1.2.2. Yapay zekanın kardiyak diğer kullanım alanları**

YZ'nin iki ana dalı olan denetimli ve denetimsiz öğrenme yöntemleriyle, son yıllarda risk tahminini iyileştirmek, büyük ölçekli tıbbi veri analizleri yapmak ve kişiye özel tedavi için hasta fenotipini belirlemek amacıyla çeşitli uygulamalar geliştirilmiştir. YZ'yi klinik pratiğe başarılı bir şekilde entegre etmek ve sürdürülebilirliğini sağlamak için bir dizi adım atılmalı ve zorluklar aşılanmalıdır (46,47).

Kalp yetmezliği (KY), dünya genelinde yaygın olan, çok sayıda nedeni ve türü olan bir hastalıktır. Tanı, evreleme ve tedavi süreçleri karmaşık olup, hasta prognozunu etkileyebilir. YZ teknolojisi, tıpta büyük bir rol oynamakta ve özellikle kardiyovasküler alanda KY'nin tanı ve tedavisini iyileştirmede kullanılmaktadır. YZ, KY'nin erken tespiti ve doğru tanı koyulmasında, EKG analizi, ileri kardiyak görüntüleme, biyomarkerler ve kardiyopulmoner stres testi gibi araçlarla yardımcı olabilir. Ancak, veri erişimi, model yorumlanabilirliği, etik sorunlar ve farklı popülasyonlar arasında genelleme gibi zorluklar bulunmaktadır. Yine de YZ'nin KY tanısındaki potansiyeli büyük olup, gelecekte bu alandaki gelişmeler umut vericidir (48).

Diğer kardiyoloji alanlarının aksine, YZ teknikleri zaten nükleer kardiyolojide birçok rutine dahil edilmiştir (49,50). YZ algoritmaları, görüntü işleme alanında uygulanarak, tamamen otomatik tek foton emisyonlu bilgisayarlı tomografi (SPECT) miyokard perfüzyon görüntülemesi (MPI)



hareket düzeltilmesi, rekonstrüksiyon, tomografik eğik yeniden yönlendirme, kantifikasyon ve sonuçların yüksek seviyede analizini mümkün kılmaktadır. Ticari olarak satılan ve ABD Gıda ve İlaç Dairesi (FDA) onaylı görüntüleme yazılımları, normal miyokard perfüzyon dağılımlarının veri tabanlarına otomatik karşılaştırmasını içermekte, bu da uzman okuyucular tarafından hipoperfüze miyokardın tanımlanmasına yardımcı olan bilgisayar destekli tanısal araçlar sunmaktadır. Bu tür otomasyonlar ve dijital görüntü verilerinin ML için kullanılabilirliği, SPECT MPI verileri ve klinik özelliklerle birlikte YZ algoritmalarının uygulanmasını mümkün kılmıştır. Bu, koroner arter hastalığının (CAD) daha iyi tahmin edilmesi, prognoz ve/veya revaskülarizasyonu iyileştirmeyi sağlamış, ayrıca yapılandırılmış raporlama ve klinik karar destek (CDS) sistemlerini desteklemiştir (49).

### 1.2.3. Yapay zekanın kardiyak risk sınıflaması ve tedavilerde kullanım alanları

Kardiyologlar, hasta bakımı için veri kullanarak kararlar alır ve genellikle diğer uzmanlıklara göre daha zengin verilere sahiptir. YZ ve ML teknikleri, veriye dayalı kararlar almak için en etkili yöntemler olarak öne çıkmaktadır. Kardiyologların AI ve ML'yi kliniklerinde kullanması, hasta bakımını iyileştirir ve verileri daha derinlemesine analiz etmelerini sağlar (13).

Örneğin hipertansiyon, yüksek kan basıncı ile karakterize edilen bir durumdur ve kalp hastalıkları gibi ciddi sağlık sorunlarına yol açabilir. YZ ve ML, hipertansiyonun tanı ve tedavisinde önemli bir rol oynamaktadır. YZ, hipertansiyonlu hastaların özelliklerine dayalı sınıflandırmalar yaparak, tedavi stratejilerini optimize eder ve tedaviye yanıtları tahmin eder. Ayrıca, YZ, farklı hipertansiyon alt tiplerini ayırt etmek için çoklu omik verileri analiz ederek doğru teşhis konmasına yardımcı olabilir. Bu sayede, daha etkili ve kişiselleştirilmiş tedavi yaklaşımları geliştirilmesi mümkün olmaktadır (2). Reel ve arkadaşları (51), endokrin hipertansiyon (EHT) alt tiplerini birincil hipertansiyondan (PHT) ayırt etmek için makine öğrenmesi algoritmaları kullandı. Random forest modeli, birincil aldosteronizm, feokromositoma ve Cushing sendromunu PHT'den ayırt etmekte en iyi performansı gösterdi (AUC = 0.95). EHT ile PHT'yi ayırmak için basit lojistik sınıflandırıcı 0.96 AUC elde etmiştir (51).

Baashar ve arkadaşları (52), KY hastalarının yeniden hastaneye yatış riskini değerlendirmek için YZ kullanımını incelemiştir. YZ, etiketli verilerle geliştirilen makine öğrenmesi algoritmaları sayesinde KY hastalarının yeniden yatışlarını tahmin etmekte kullanılabileceğini savunmuştur. Çalışmada, 50.000'den fazla KY hastası üzerinde yapılan tahminlerde YZ modellerinin,

geleneksel istatistiksel modellere göre daha yüksek doğruluk sağladığı bulunmuştur. Bu, YZ'nin KY yönetiminde etkili bir araç olabileceğini göstermektedir (52).

Betancur ve ark., 2619 hasta üzerinde SPECT MPI çalışması yaparak, 28 klinik, 17 stres testi ve 25 görüntüleme değişkenini (TPD dahil) bir YZ algoritmasına entegre ederek büyük kardiyak olayları (MACE) tahmin etmeye çalışmıştır. Bu çalışmada, tüm verilerle yapılan ML (ML-combined) modelinin, yalnızca görüntüleme verileriyle yapılan ML (ML-imaging) modeline kıyasla daha yüksek doğruluk sağladığı (AUC 0.81 vs 0.78;  $P < .01$ ) ve doktor tanısına göre risk sınıflandırmasında %26 daha iyi sonuç verdiği bulunmuştur ( $P < .001$ ). Bu bulgular, YZ'nin kişiselleştirilmiş MACE risk hesaplamaları için klinik ve görüntüleme verilerinin entegrasyonunda etkili olabileceğini göstermektedir (53).

YZ, doktorların işlerini kolaylaştırarak tedavi seçimlerinde daha iyi sonuçlar elde edilmesine yardımcı olur. Gelecekte, ML yöntemlerinin daha yaygın ve erişilebilir hale gelmesi beklenmektedir, ancak doktorların uzmanlık bilgisi hala kritik öneme sahip olacağı düşünülmektedir (13).

## 2. Yapay zekanın kısıtlılıkları

YZ, görüntüleme sürecinin her aşamasında zamanlama, verimlilik ve eksik tanımlar gibi sorunları azaltarak maliyeti düşürebilir ve değeri artırabilir. YZ'nin ana kullanım alanları, hastalık fenotiplemesi, tanı desteği ve görüntü yorumlama olacaktır. İlgili klinik ve görüntüleme verilerinin küme analizleri ile hastalıkları daha iyi tanımlama fırsatları sağlanabilir. Tanı desteği, otomatik görüntü segmentasyonu ve ölçümlerle sunulacaktır. Ayrıca, görüntüleme verileri ile elektronik sağlık kayıtları ve patoloji verilerinin birleşimi, tedaviyi kişiselleştirme ve yeni içgörüler elde etme fırsatları sunacağı tahmin edilmektedir (35). Ancak ML'in klinik ortamlarda kullanımı heyecan verici uygulamalar sunsa da birkaç önemli sınırlamaya sahiptir. ML algoritmaları, kullanılan verilerin kalitesine bağlıdır; eksik veya düşük kaliteli veriler, algoritmaların doğruluğunu bozabilir. Ayrıca, elektronik sağlık kaydı verileri ve sosyal, kültürel faktörler gibi önemli bilgi kaynaklarını bulmak zor olabilir. Eğitim sorunları ve model güncellemeleri de ML'nin başarısını sınırlayan faktörlerdir. Algoritmalar zamanla eğitime aşırı uyum sağlayarak verilerdeki ilişkileri doğru şekilde yansıtamayabilir (15).

Son yıllarda ML ve genel olarak YZ önemli ölçüde ilerlemiş olsa da teknoloji hala birçok başka, daha köklü yöntemle karşılaştırıldığında erken aşamalarda. Bu durum, ML'in tıbbi pratiğe entegrasyonunu zorlaştırabilir. ML'in tıpta uygulanması maliyetli olabilir, bu da geniş çapta kullanımını

engelleyebilir. MLin, doktorların iş akışını pek çok olumlu şekilde devrim niteliğinde değiştirme potansiyeline sahip olduğu makul bir varsayım olsa da bu teknolojilerin ilk uygulanması, sağlık hizmeti sağlayıcılarının günlük rutinlerine uyum sağlamakta zorluk yaşaması nedeniyle sıkıntılı olabilir. Cuocolo ve arkadaşlarına göre (20), ML algoritmalarının “kara kutu” doğası ve kliniklerin verilerin yorumlarını anlamada ve güven duymada yaşadıkları zorluklar, aşılması gereken en büyük engel olabilir.

YZ'nin başarılı bir şekilde kullanılabilmesi için güçlü yönlerinin, sınırlamalarının, fırsatlarının ve risklerinin doğru bir şekilde anlaşılması önemlidir. Makine öğrenmesinin temel özellikleri, geliştirilme süreçleri ve hangi durumlarda uygun olmadığı gibi konular da net bir şekilde kavranmalıdır. Ayrıca, YZ'nin eğitim verilerinde yer almayan popülasyonlara uygulandığında ortaya çıkabilecek önyargılar, veri güvenliği tehditleri ve veri sahipliği gibi potansiyel riskler dikkate alınmalıdır. Gelecek, YZ'nin tıpta büyük bir potansiyele sahip olduğunu göstermektedir, ancak sağlık profesyonellerinin bu araçları doğru ve etik bir şekilde kullanmaları gerekmektedir. YZ'nin tıpta etkin bir şekilde uygulanabilmesi için bilgisayar bilimcileri, klinik araştırmacılar, klinisyenler ve diğer paydaşlar arasında güçlü bir iş birliği gereklidir. Doğru veri kaynaklarının seçilmesi, yorumlama, doğrulama ve genellenebilirlik gibi konularda karşılaşılan zorlukların aşılması önemlidir. Kardiyoloji ve genel olarak tıpta YZ'nin geleceği, paydaşlar arasındaki iş birliğinin devam etmesiyle parlak bir şekilde gelişmeye devam etmektedir (54).

### 3. Sonuç

Sonuç olarak, bu alanın geniş çapta uygulanabilmesi için daha fazla keşif ve benimsenmesi gerekmektedir. YZ'nin kardiyovasküler uzmanların yerini alması beklenmemelidir; bunun yerine, YZ, uzmanların klinik becerilerini geliştirmelerine, daha doğru ve hızlı teşhisler koymalarına ve genel bakım kalitesini iyileştirmelerine yardımcı olabilecek bir araç olarak büyük potansiyel taşır. YZ sistemlerinin başarılı bir şekilde uygulanabilmesi için, olası uygulama sorunlarının belirlenip çözülmesi önemlidir. Bu yaklaşım, YZ'nin kardiyovasküler tıpta tam potansiyeline ulaşabilmesi için kritik bir adım olacaktır. YZ'nin performansı, giriş verilerinin kalitesine ve algoritma geliştirme sürecindeki titizliğe bağlıdır. Alan hala gelişim aşamasında olsa da YZ'nin geniş klinik uygulamalarında kullanılmadan önce, büyük ve iyi etiketlenmiş veri setlerinde prospektif doğrulama yapılması ve daha sorunsuz bilgi teknolojisi tabanlı veri toplama/entegrasyonunun sağlanması gerekmektedir.

## Kaynaklar

1. Xu D, Liu R, Xu H, Zhang Z, Li W, Zhang Y, et al. Adoption of two-dimensional ultrasound gastrointestinal filling contrast on artificial intelligence algorithm in clinical diagnosis of gastric cancer. *Comput Math Methods Med*. 2022;2022:7385344. doi: 10.1155/2022/7385344.
2. Sun X, Yin Y, Yang Q, Huo T. Artificial intelligence in cardiovascular diseases: diagnostic and therapeutic perspectives. *Eur J Med Res*. 2023;28(1):242. doi: 10.1186/s40001-023-01065-y
3. *Montull L, Slapsinskaite-Dackeviciene A, Kiely J, Hristovski R, Balague N. Integrative proposals of sports monitoring: subjective outperforms objective monitoring. Sports Med Open*. 2022;8(1):41. doi: 10.1186/s40798-022-00432-z.
4. Emile SH, Hamid HKS. Fighting COVID-19, a place for artificial intelligence. *Transbound Emerg Dis*. 2020;67(5):1754–1755. doi: 10.1111/tbed.13648
5. Dankwa-Mullan I, Rivo M, Sepulveda M, Park Y, Snowdon J, Rhee K. Transforming diabetes care through artificial intelligence: the future is here. *Popul Health Manag*. 2019;22(3):229–242. doi: 10.1089/pop.2018.0129.
6. 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? *J Geriatr Cardiol*. 2019;16(8):585–591. doi: 10.11909/j.issn.1671-5411.2019.08.010.
7. Goodswen SJ, Barratt JLN, Kennedy PJ, Kaufer A, Calarco L, Ellis JT. Machine learning and applications in microbiology. *FEMS Microbiol Rev*. 2021;45:5. doi: 10.1093/femsre/fuab015.
8. Zhu R, Jiang C, Wang X, Wang S, Zheng H, Tang H. Privacy-preserving construction of generalized linear mixed model for biomedical computation. *Bioinformatics*. 2020;36(1):128–135. doi: 10.1093/bioinformatics/btaa478.
9. Lüscher TE, Wenzl FA, D’Ascenzo F, Friedman PA, Antoniadou C. Artificial intelligence in cardiovascular medicine: clinical applications. *Eur Heart J*. 2024;45(40):4291-4304. doi: 10.1093/eurheartj/ehae465
10. Cho H, Keenan G, Madandola OO, Dos Santos FC, Macieira TGR, Bjaradottir RI, et al. Assessing the usability of a clinical decision support system: heuristic evaluation. *JMIR Hum Factors*. 2022;9(2):e31758. doi: 10.2196/31758.
11. Alfraih A, Tago A, Lacombe M, Kussmaul WG. Cardiology: What You May Have Missed in 2023. *Ann Intern Med*. 2024;177(5\_Supplement):S3-S14. doi: 10.7326/M24-0581.

12. Muller O, Trana C, Roux Y, Pruvot E, Graf D, Jeanrenaud X, Locca D, Vogt P. *Cardiologie [Cardiology]*. *Rev Med Suisse*. 2011;7(277):8-10, 12-5.
13. Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. *Artificial Intelligence in Cardiology*. *J Am Coll Cardiol*. 2018;71(23):2668-2679. doi: 10.1016/j.jacc.2018.03.521.
14. Ranka S, Reddy M, Noheria A. *Artificial intelligence in cardiovascular medicine*. *Curr Opin Cardiol*. 2021;36(1):26-35. doi: 10.1097/HCO.0000000000000812.
15. Itchhaporia D. *Artificial intelligence in cardiology*. *Trends Cardiovasc Med*. 2022;32(1):34-41. doi: 10.1016/j.tcm.2020.11.007.
16. Sandeep B, Liu X, Huang X, Wang X, Mao L, Xiao Z. *Feasibility of artificial intelligence its current status, clinical applications, and future direction in cardiovascular disease*. *Curr Probl Cardiol*. 2024;49(2):102349. doi: 10.1016/j.cpcardiol.2023.102349
17. Shameer K, Badgeley MA, Miotto R, Glicksberg BS, Morgan JW, Dudley JT. *Translational bioinformatics in the era of real-time biomedical, health care and wellness data streams*. *Brief Bioinform*. 2017;18(1):105-124. doi:10.1093/bib/bbw103
18. Muse ED, Barrett PM, Steinhubl SR, Topol EJ. *Towards a smart medical home*. *Lancet*. 2017;10067:358-389. doi:10.1016/S0140-6736(17)30819-1
19. Krittanawong C, Zhang HJ, Wang Z, Aydar M, Kitai T. *Artificial intelligence in precision cardiovascular medicine*. *J Am Coll Cardiol*. 2017;69(21):2657-2664. doi:10.1016/j.jacc.2017.03.571
20. Cuocolo R, Perillo T, De Rosa E, Ugga L, Petretta M. *Current applications of big data and machine learning in cardiology*. *J Geriatr Cardiol*. 2019;16(8):601-607. doi:10.11909/j.issn.1671-5411.2019.08.002
21. Itchhaporia D, Snow PB, Almassy RJ, Oetgen WJ. *Artificial neural networks: current status in cardiovascular medicine*. *JACC*. 1996;28(3):515-521.
22. Lyon A, Mincholé A, Martínez JP, Laguna P, Rodriguez B. *Computational techniques for ECG analysis and interpretation in light of their contribution to medical advances*. *J R Soc Interface*. 2018;15(138):20170821. doi:10.1098/rsif.2017.0821
23. Al'Aref SJ, Anchouche K, Singh G, Slomka PJ, Kolli KK, Kumar A, et al. *Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging*. *Eur Heart J*. 2019;40(24):1975-1986. doi:10.1093/eurheartj/ehz405

24. Kannathal N, Acharya UR, Lim CM, Sadasivan PK, Krishnan SM. Classification of cardiac patient states using artificial neural networks. *Exp Clin Cardiol.* 2003;8(4):206-211
25. Gupta A, Harvey CJ, DeBauge A, Shomaji S, Yao Z, Noheria A. Machine learning to classify left ventricular hypertrophy using ECG feature extraction by variational autoencoder. *medRxiv [Preprint].* 2024:2024.10.14.24315460. doi: 10.1101/2024.10.14.24315460
26. Ranka S, Reddy M, Noheria A. Artificial intelligence in cardiovascular medicine. *Curr Opin Cardiol* 2021; 36:26–35.
27. Ose B, Sattar Z, Gupta A, Toquica C, Harvey C, Noheria A. Artificial Intelligence Interpretation of the Electrocardiogram: A State-of-the-Art Review. *Curr Cardiol Rep* 2024; 26:561–580.
28. Harvey CJ, Shomaji S, Yao Z, Noheria A. Comparison of Autoencoder Encodings for ECG Representation in Downstream Prediction Tasks. *arXiv preprint* 2024:2410.02937.
29. Dwivedi T, Xue J, Treiman D, Dubey A, Albert D. Machine learning models of 6-lead ECGs for the interpretation of left ventricular hypertrophy (LVH). *J Electrocardiol.* 2023; 77:62-67. doi: 10.1016/j.jelectrocard.2022.12.001
30. Khurshid S, Friedman S, Pirruccello JP, Di Achille P, Diamant N, Anderson CD, et al. Deep Learning to Predict Cardiac Magnetic Resonance-Derived Left Ventricular Mass and Hypertrophy From 12-Lead ECGs. *Circ Cardiovasc Imaging.* 2021;14(6): e012281. doi: 10.1161/CIRCIMAGING.120.012281
31. Rjoob K, Bond R, Finlay D, McGilligan V, Leslie SJ, Rababah A, Guldenring D, Iftikhar A, Knoery C, McShane A, Peace A. Machine learning techniques for detecting electrode misplacement and interchanges when recording ECGs: A systematic review and meta-analysis. *J Electrocardiol.* 2020; 62:116-123. doi: 10.1016/j.jelectrocard.2020.08.013
32. Cai C, Imai T, Hasumi E, Fujitsu K. One-shot screening: Utilization of a two-dimensional convolutional neural network for automatic detection of left ventricular hypertrophy using electrocardiograms. *Comput Methods Programs Biomed.* 2024; 247:108097. doi: 10.1016/j.cmpb.2024.108097
33. Rabkin SW. Searching for the Best Machine Learning Algorithm for the Detection of Left Ventricular Hypertrophy from the ECG: A Review. *Bioengineering (Basel).* 2024;11(5):489. doi: 10.3390/bioengineering11050489
34. Ghesu FC, Georgescu B, Zheng Y, Grbic S, Maier A, Hornegger A, et al. Multi-scale deep reinforcement learning for real-time 3D landmark dete-

- ction in CT scans. *IEEE Trans Pattern Anal Mach Intell.* 2019; 41:176-189. doi:10.1109/TPAMI.2018.2838326
35. Dey D, Slomka PJ, Leeson P, Comaniciu D, Shrestha S, Sengupta PP, et al. Artificial intelligence in cardiovascular imaging. *JACC.* 2019;73(11):1317-1335. doi: 10.1016/j.jacc.2018.12.074
  36. Seetharam K, Min JK. Artificial Intelligence and Machine Learning in Cardiovascular Imaging. *Methodist Debakey Cardiovasc J.* 2020;16(4):263-271. doi: 10.14797/mdcj-16-4-263
  37. Motwani M, Dey D, Berman DS, Germano G, Achenbach S, Al-Mallah MH, et al. Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease: a 5-year multicentre prospective registry analysis. *Eur Heart J.* 2017;38(7):500-507. doi: 10.1093/eurheartj/ehw188.
  38. Baskaran L, Al'Aref SJ, Maliakal G, Lee BC, Xu Z, Choi JW, et al. Automatic segmentation of multiple cardiovascular structures from cardiac computed tomography angiography images using deep learning. *PLoS One.* 2020 May 6;15(5):e0232573. doi: 10.1371/journal.pone.0232573
  39. Han D, Kolli KK, Al'Aref SJ, Baskaran L, van Rosendaal AR, Gransar H, et al. Machine Learning Framework to Identify Individuals at Risk of Rapid Progression of Coronary Atherosclerosis: From the PARADIGM Registry. *J Am Heart Assoc.* 2020;9(5):e013958. doi: 10.1161/JAHA.119.013958.
  40. Feuchtner G, Kerber J, Burghard P, Dichtl W, Friedrich G, Bonaros N, et al. The high-risk criteria low-attenuation plaque. *Eur Heart J Cardiovasc Imaging* 2017; 18: 772–9.
  41. Jiang B, Guo N, Ge Y, Zhang L, Oudkerk M, Xie X. Development and application of artificial intelligence in cardiac imaging. *Br J Radiol.* 2020;93(1113):20190812. doi: 10.1259/bjr.20190812
  42. Zreik M, van Hamersvelt RW, Wolterink JM, Leiner T, Viergever MA, Isgum I. A recurrent cnn for automatic detection and classification of coronary artery plaque and stenosis in coronary CT angiography. *IEEE Trans Med Imaging* 2019; 38: 1588–98. doi: 10.1109/TMI.2018.2883807
  43. Tao Q, Yan W, Wang Y, Paiman EHM, Shamoun DP, Garg P, et al. Deep learning-based method for fully automatic quantification of left ventricle function from cine Mr images: a multivendor, multicenter study. *Radiology* 2019; 290: 81–8. doi: 10.1148/radiol.2018180513
  44. Ruijsink B, Puyol-Antón E, Oksuz I, Sinclair M, Bai W, Schnabel JA, et al. Fully automated, quality-controlled cardiac analysis from CMR: validation and large-scale application to characterize cardiac function. *JACC Cardiovasc Imaging* 2019;17 Jul 2019. doi: 10.1016/j.jcmg.2019.05.030



45. Baeßler B, Mannil M, Maintz D, Alkadhi H, Manka R. Texture analysis and machine learning of non-contrast T1-weighted MR images in patients with hypertrophic cardiomyopathy-Preliminary results. *Eur J Radiol.* 2018; 102:61-67. doi: 10.1016/j.ejrad.2018.03.013
46. Alis D, Guler A, Yergin M, Asmakutlu O. Assessment of ventricular tachyarrhythmia in patients with hypertrophic cardiomyopathy with machine learning-based texture analysis of late gadolinium enhancement cardiac MRI. *Diagn Interv Imaging* 2019. doi: 10.1016/j.diii.2019.10.005
47. Manlhiot C, van den Eynde J, Kutty S, Ross HJ. A Primer on the Present State and Future Prospects for Machine Learning and Artificial Intelligence Applications in Cardiology. *Can J Cardiol.* 2022;38(2):169-184. doi: 10.1016/j.cjca.2021.11.009
48. Medhi D, Kamidi SR, Mamatha Sree KP, Shaikh S, Rasheed S, Thengu Murichathil AH, et al. Artificial Intelligence and Its Role in Diagnosing Heart Failure: A Narrative Review. *Cureus.* 2024;16(5):e59661. doi: 10.7759/cureus.59661
49. Garcia EV, Klein JL, Taylor AT. Clinical decision support systems in myocardial perfusion imaging. *J Nucl Cardiol.* 2014;21(3):427-39; quiz 440. doi: 10.1007/s12350-014-9857-9
50. Malek H, Yaghoobi N, Hedayati R. Artifacts in Quantitative analysis of myocardial perfusion SPECT, using Cedars-Sinai QPS Software. *J Nucl Cardiol.* 2017;24(2):534-542. doi: 10.1007/s12350-016-0726-6
51. Reel PS, Reel S, van Kralingen JC, Langton K, Lang K, Erlic Z, et al. Machine learning for classification of hypertension subtypes using multi-omics: A multi-centre, retrospective, data-driven study. *EBioMedicine.* 2022;84:104276. doi: 10.1016/j.ebiom.2022.104276
52. Baashar Y, Alkawsi G, Alhussian H, Capretz LE, Alwadain A, Alkahtani AA, Almomani M. Effectiveness of Artificial Intelligence Models for Cardiovascular Disease Prediction: Network Meta-Analysis. *Comput Intell Neurosci.* 2022;2022:5849995. doi: 10.1155/2022/5849995
53. Betancur J, Otaki Y, Motwani M, Fish MB, Lemley M, Dey D, et al. Prognostic Value of Combined Clinical and Myocardial Perfusion Imaging Data Using Machine Learning. *JACC Cardiovasc Imaging.* 2018;11(7):1000-1009. doi: 10.1016/j.jcmg.2017.07.024
54. Lopez-Jimenez F, Attia Z, Arruda-Olson AM, Carter R, Chareontha-itawee P, Jouni H, et al. Artificial Intelligence in Cardiology: Present and Future. *Mayo Clin Proc.* 2020;95(5):1015-1039. doi: 10.1016/j.mayocp.2020.01.038