

Kalp Hastalığı Risk Tahmini için Makine Öğrenmesi Tabanlı Mobil Uygulama

Bartu Başaran^{1*}, Ali Akdağ^{2*}

¹ Bilgisayar Mühendisliği Bölümü, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye (basaranbartu734@gmail.com)

² Bilgisayar Mühendisliği Bölümü, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye (ali.akdag@gop.edu.tr)

Özet – Sunulan çalışmada, kalp hastalığı riskinin erken ve güvenilir biçimde tahmin edilmesini sağlayan makine öğrenmesi tabanlı bir mobil uygulama geliştirilmiştir. Dokuz farklı algoritma değerlendirilmiş, en yüksek doğruluğa (%86,81) sahip olan k-NN modeline rağmen, pratik uygulamalarda daha dengeli sonuçlar sunan Random Forest algoritması (%82,42 doğruluk) tercih edilmiştir. Uygulama, 13 sağlık parametresini (yaş, cinsiyet, kolesterol, kan basıncı vb.) kullanarak kalp hastalığı riskini tahmin eder. Sade ve erişilebilir arayüzü ile özellikle ileri yaştaki bireyler için optimize edilmiştir. Çalışma, bireysel farkındalığı artırmayı ve sağlık hizmetlerine yönelimi teşvik etmeyi amaçlamaktadır.

Anahtar Kelimeler – Kalp hastalığı tespiti, makine öğrenmesi, mobil sağlık uygulamaları, yapay zeka

A Machine Learning-Based Mobile Application for Predicting Heart Disease Risk

Abstract– This study presents the development of a mobile application that enables early and reliable prediction of heart disease risk using machine learning techniques. Nine different algorithms were evaluated, and although the k-Nearest Neighbors (k-NN) model achieved the highest accuracy (86.81%), the Random Forest algorithm was preferred due to its more balanced performance in practical scenarios (accuracy: 82.42%). The application estimates heart disease risk based on 13 health parameters, including age, gender, cholesterol level, and blood pressure. With its simple and accessible interface, the app is optimized particularly for older adults. The primary aim of the study is to raise individual awareness and encourage timely engagement with healthcare services.

Keywords – Heart disease detection, machine learning, mobile health applications, artificial intelligence

I. GİRİŞ

Kalp hastalıkları, dünya genelinde önde gelen ölüm nedenleri arasındadır. Dünya Sağlık Örgütü (DSÖ) verilerine göre, küresel ölümlerin çoğunluğu kalp hastalıkları nedeniyle gerçekleşmektedir [1]. Kalp hastalıkları, erken teşhis ve yaşam tarzı değişiklikleriyle büyük ölçüde önlenebilir hastalıklardır. Ancak bireylerin bu önlemlerden yeterince yararlanamaması, bilgi eksikliği ve sağlık hizmetlerine erişimdeki engellerle ilişkilidir [2], [3], [4], [5], [6]. Bu bağlamda, makine öğrenimi destekli karar destek sistemleri büyük veri kümelerini analiz ederek kalp hastalıkları için risk faktörlerini belirleyebilir, böylece hem bireysel hem de toplumsal sağlık yararı sağlayabilir ve bireyleri sağlık hizmetlerine başvurmaya teşvik edebilir.

Literatürde makine öğrenimi temelli kalp hastalığı riskini belirleyen çalışmalara rastlamak mümkündür.

Ogunpola ve ark. çalışmalarında kardiyovasküler hastalıkların erken tespiti için K-Nearest Neighbors (KNN), Support Vector Machine (SVM), Lojistik Regresyon, CNN, Gradient Boost, XGBoost ve Random Forest gibi çeşitli sınıflandırma algoritmalarını test etmiştir. En iyi sonucu %98,50 doğruluk oranı ve %98,71 F1 skoru ile XGBoost modeli vermiştir [7].

Baghdadi ve ark. çalışmalarında kardiyovasküler hastalıkların erken tanısı için yeni, etkili ve verimli makine öğrenme algoritmaları geliştirmiş ve otomatik özellik seçimi yaparak Catboost modeliyle %90,94 doğruluk ve %92,3 F1 skoru elde etmişlerdir [8].

Gürgen ve Serttaş çalışmalarında, Kalp Yetmezliği hastalığının erken teşhisini sağlamak amacıyla Kaggle veri setinden elde edilen 11 özelliğe sahip hasta verileri üzerinde CART, K-Nearest Neighbours, Lojistik Regresyon, Random Forest, AdaBoost, XGBoost, LightGBM ve CatBoost algoritmalarını karşılaştırmışlardır. Sonuç olarak Random Forest, F1 skoru 0,98, ROC AUC 0,999 ve doğruluk 0,99 değerleri ile en başarılı tahmin performansını sergilemiştir [9].

Detrano ve arkadaşlarının yaptığı çalışma da Cleveland Clinic'ten (n = 303) elde edilen klinik ve non-invaziv test verilerinden yola çıkarak yeni bir diskriminant fonksiyonu ile koroner arter hastalığı (KAH) olasılıklarının hesaplanabilirliğini değerlendirmek. Yöntem olarak literatürden derlenen Bayes temelli CADENZA algoritmasıyla karşılaştırılmıştır [10].

Muhammad Amir Khan ve Tehseen Mazhar arkadaşları, UCI Cleveland Heart Disease veri setini (303 kayıt) kullanarak; IoMT tabanlı giyilebilir ve klinik cihazlardan elde edilen veriler üzerinde modifiye edilmiş Yapay Arı Kolonisi

(M-ABC) algoritması ile en bilgilendirici özellikleri seçmiş, bu altküme ile K-En Yakın Komşu (KNN) sınıflayıcısını leave-one-subject-out çapraz doğrulama ile eğitmişlerdir; çalışma sonucunda, M-ABC ile seçilen sınırlı özellikler hem sınıflandırma doğruluğunu artırmış hem de eğitim süresini önemli ölçüde kısaltmıştır [11].

Tschay Admassu Assegie Injibara Üniversitesi'nden, Kaggle makine öğrenimi veri havuzundaki 1025 gözlemlili Heart Disease veri seti (%48,68 hastalık negatif, %51,32 hastalık pozitif) üzerinde k-En Yakın Komşu (KNN) algoritmasıyla bir kalp hastalığı tahmin modeli geliştirmiş; en uygun komşu sayısı ve mesafe ölçütü belirlenerek test setinde %91,99 doğruluk oranı elde etmiştir [12].

Shorewala çalışmasında, 70.000 kayıttan oluşan "Cardiovascular Disease Dataset" üzerinde K-Nearest Neighbors, İkili Lojistik Sınıflandırma ve Naive Bayes gibi taban sınıflandırıcıları ile bagging, boosting ve stacking gibi topluluk öğrenme teknikleri kıyaslanmıştır. En etkili sonuç ise KNN, Random Forest ve SVM'in bir arada kullanıldığı stacking modeliyle %75,1 doğruluk oranı sunan yöntem olmuştur [13].

Madhumita Pal ve Smita Parija arkadaşları, Kaggle Kalp Hastalığı veri setini (303 kayıt, 14 öznitelik) kullandıkları Random Forest sınıflayıcı ile %86,9 doğruluk, %90,6 duyarlılık, %82,7 özgüllük ve %93,3 ROC AUC elde etmişlerdir [14].

Ch Anwar ul Hassan ve arkadaşları, UCI Cleveland Kalp Hastalığı veri seti (303 kayıt, 14 öznitelik) üzerinde on bir makine öğrenimi sınıflayıcıyı kıyaslayıp Gradient Boosted Trees ve Çok Katmanlı Algılayıcı ile %95, Random Forest ile %96 doğruluk elde etmişlerdir [15].

Yagyanath Rimal ve arkadaşları, açık kaynak Cleveland veri setini (303 kayıt, 13 özellik) Logistic Regression, SVM, KNN ve Random Forest modelleriyle 5 katlı çapraz doğrulama altında değerlendirip; LR ve KNN ile %81 tek model doğruluğu, RF ile %94 makro doğruluk, %96 precision ve %97 recall elde etmişlerdir [16].

Alhaam Alariyibi, Mohamed El-Jarai ve Abdelsalam Maatuk, UCI Cleveland Kalp Hastalığı veri seti (303 kayıt, 14 öznitelik) üzerinde J48, Random Forest ve Naive Bayes algoritmalarını karşılaştırarak Random Forest ile %99,24 doğrulukla en iyi sonucu almışlardır [17].

Md. Shaheenur Islam Sumon ve arkadaşları, açık kaynaklı kalp hastalığı veri setini (1 190 kayıt, 11 öznitelik) kullanarak "CardioTabNet" adlı hibrit TabTransformer tabanlı modelde önce özellik çıkartıp Random Forest ile sıraladıkları en bilgilendirici öznitelikleri seçmiş; bu altküme ile hiperayarlı ExtraTree sınıflayıcısını eğiterek %94,1 doğruluk ve %95,0 AUC elde etmişlerdir [18].

Al-Alshaiikh ve ark. çalışmalarında, GA ve RFEM yöntemleriyle seçilen özellikler ile USCOM kullanılarak veri dengesizliği giderildikten sonra MLDCNN tabanlı ve AEHOM ile optimize edilen ML-HDPM modeli geliştirilmiştir. Sonuç olarak, model %95,5 doğruluk, %94,8 kesinlik, %96,2 duyarlılık, %91,5 F1 skoru ve %89,7 özgüllük oranlarına ulaşmıştır [19].

Abdullah çalışmasında, veri iyileştirme teknikleriyle desteklenen Geliştirilmiş Çok Katmanlı Algılayıcı (EMLP) çerçevesini kullanarak CDC kalp hastalığı veri seti üzerinde %92 doğruluk oranı elde etmiştir [20].

Coşar ve Deniz çalışmalarında örnek bir veri seti üzerinde Random Forest, Lojistik Regresyon ve kNN algoritmalarını

karşılaştırmış; Random Forest ile %88, Lojistik Regresyon ile %85 ve kNN ile %70 doğruluk elde etmişlerdir [21].

Küçükmanisa ve Kilimeci çalışmalarında, 303 bireyin yer aldığı 14 özellikli veri seti üzerinde K-Nearest Neighbors, Gaussian Naive Bayes, Lojistik Regresyon, Random Forest, Gradient Boosting ve Yapay Sinir Ağları yöntemlerini karşılaştırmışlardır. Sonuç olarak, Gradient Boosting modeli %95 doğruluk oranı ile, Yapay Sinir Ağları ise %90,1 doğruluk oranı ile en başarılı performansı sergilemiştir [22].

Bu alanda yapılan bilimsel çalışmaların yanı sıra, çeşitli kurum ve kuruluşlar da bireylerin kalp hastalığı risklerini değerlendirebilmeleri amacıyla web tabanlı uygulamalar geliştirmiştir. Aşağıda bu çalışmalardan bazı örneklere yer verilmiştir.

Türk Kardiyoloji Derneği tarafından yapılan çalışmada yaş, LDL kolesterol, HDL kolesterol, kan basıncı, diyabet hastası olup olunmadığı ve sigara kullanmadığı bilgilerini istiyor ve bu çalışma web sitesinde yer alıyor [23].

Memorial tarafından yapılan çalışmada yaş, boy, kilo, cinsiyet, daha öncesinde yaşadığım sağlık sorunları (inme, bypass, anjiyoplasti vb.), ebeveynlerin bu sağlık sorunlarını yaşayıp yaşamadığı, sigara kullanımı, diyabet hastalığı, HDL kolesterol, kan basıncı, tansiyon ilacı kullanıp kullanmadığı, fiziksel aktivite sıklığı, meyve sebze yeme sıklığı, hayvansal yağ kullanımı değerlerini kullanıcıdan alıp kullanıcıya kalp hastalığı risk değerini gösteriyor ve bu çalışma web sitesinde yer alıyor [24].

Pan American Health Organization tarafından yapılan çalışmada ise bireyin daha önce kalp hastalığı geçirip geçirmediği, böbrek hastalığı yaşayıp yaşamadığı, diyabet olup olmadığı, kolesterol değeri, yaş, sigara kullanımı, kilo, yaş, tansiyon değeri, boy değişkenlerini esas alıp kalp hastalığı risk değerini kullanıcıya gösteriyor [25].

American College of Cardiology tarafından yapılan çalışmada bireyin yaş, cinsiyet, ırk, tansiyon değerleri, kolesterol değeri, HDL kolesterol, LDL kolesterol değerleri, diyabet değerleri, sigara kullanımı, hipertansiyon hastalığına sahip olup olmadığı, statin (kolesterol seviyesini düşürmede kullanılan bir ilaç) kullanıp kullanmadığı, aspirin tedavisi alıp almadığı bilgisine göre çıkarım yapan bir web sitesi sunuluyor [26].

American Heart Association tarafından yapılan çalışmada ise cinsiyet, yaş, ırk, kolesterol değeri, LDL kolesterol, HDL kolesterol, statin tedavisi, kan basıncı, hipertansiyon hastalığına sahip olup olmadığı, diyabet hastalığına sahip olup olmadığı, sigara kullanımı, aspirin tedavisi alıp almadığı sorularını kullanıcılara sorup cevapları aldıktan sonra risk değerini kullanıcıya gösteren çalışma web sitesinde yer almaktadır [27].

Kalp hastalığı riski için birçok makine öğrenmesi modeli ve web aracı geliştirilmiştir. Ancak çoğu, sadece modelleme sürecine odaklanmış ve mobil kullanıcı deneyimi açısından sınırlı kalmıştır. Ayrıca, mevcut mobil uygulamaların çoğu kapalı kutu (black-box) yapıda olduğundan, algoritmik şeffaflık ve performans karşılaştırması açısından sınırlı bilgi sunmaktadır.

Literatürdeki boşluğu doldurmak amacıyla farklı makine öğrenmesi algoritmalarının performansları çok yönlü şekilde değerlendirildi ve en dengeli sonuç veren model, kullanıcı dostu bir mobil uygulamaya entegre edildi.

Uygulama, yaş, cinsiyet, kolesterol, kan basıncı gibi 13 sağlık parametresini kullanarak kalp hastalığı riskini tahmin

etmekte ve sade, erişilebilir arayüzü sayesinde özellikle ileri yaştaki bireylerin kullanımı için optimize edilmiştir.

Üyelik sistemi sayesinde kullanıcılar, geçmiş verilerini görüntüleyerek sağlık takibini sürdürebilmekte, böylece uzun vadeli kişisel sağlık farkındalığı desteklenmektedir.

Çalışma, algoritma karşılaştırması ve mobil uygulama geliştirme yönleriyle literatürde farklılaşmaktadır. Çalışma kapsamında ZeroR, OneR, Naive Bayes, J48 karar ağacı, Rastgele Orman, Lojistik Regresyon, k-NN, Çok Katmanlı Algılayıcılar ve Destek Vektör Makineleri gibi farklı makine öğrenmesi algoritmaları uygulanmış; doğruluk, kesinlik, duyarlılık ve F1 skoru gibi ölçütler üzerinden performansları karşılaştırılmıştır. En iyi sonuç veren model mobil uygulamaya entegre edilmiştir.

II. MATERYAL VE YÖNTEM

A. Veri Seti

Bu çalışma kapsamında kullanılan veri seti, Kaggle platformundan temin edilmiş olan "Heart Disease" veri setidir [28]. Bu veri seti bireylerin yaş, cinsiyet, dinlenme kan basıncı, kolesterol düzeyi, maksimum nabız gibi çeşitli tıbbi ve fiziksel bilgilerini içermektedir. Ayrıca göğüs ağrısı tipi, açlık kan şekeri durumu, dinlenme elektrokardiyografi sonuçları ve egzersize bağlı göğüs ağrısının varlığı gibi kalp hastalığı riskiyle ilişkili önemli parametreler de yer almaktadır.

Tablo 1. "Heart Disease" veri kümesi

Öznitelik	Tanımlama	Değerler
Age	Yaş	Yıl Olarak Yaş
Sex	Cinsiyet	1 = Erkek, 0 = Kadın
Cp	Göğüs Ağrısı Tipi	0 = Tipik anjina, 1 = Atipik anjina, 2 = Anjina dışı ağrı, 3 = Asemptomatik
Trestbps	Dinlenme Kan basıncı	Hastaneye kabulde ölçülen kan basıncı (mm Hg)
Chol	Serum Kolesterol	Serum kolesterol seviyesi (mg/dl)
Fbs	Açlık Kan Şekeri	Açlık kan şekeri > 120 mg/dl (1 = Doğru, 0 = Yanlış)
Restecg	Dinlenme EKG Sonucu	0= Normal, 1 = ST-T anormalliği, 2 = Sol ventrikül hipertrofisi
Thalach	Maksimum Kalp Atış Hızı	Ulaşılan maksimum kalp atış hızı
Exang	Egzersize Bağlı Anjina	1 = Evet, 0 = Hayır
Oldpeak	St Depresyonu	Egzersiz sonrası ST depresyonu
Slope	St Segment Eğimi	0 = Yukarı eğimli, 1 = Düz, 2 = Aşağı eğimli
Ca	Büyük Damar Sayısı	Floroskopi ile renklendirilen büyük damar sayısı (0-3)
Thal	Talasemi Durumu	0 = Hata, 1 = Sabit defekt, 2 = Normal, 3 = Geri dönüşlü defekt
Target	Hastalık Durumu	0 = Hastalık yok, 1 = Hastalık var

Toplam 303 bireye ait kayıt içeren veri setinde, 207 erkek ve 96 kadın bulunmaktadır. Bu bireylerden 165'inde kalp hastalığı riski tespit edilirken, 138'inde böyle bir risk bulunmamıştır. Tablo 1'de veri setinde yer alan öznitelikler ve açıklamaları sunulmuştur.

Veri seti, modelin eğitim işlemi ve doğruluğunun değerlendirilmesi amacıyla eğitim (train) ve test (test) olmak

üzere ikiye bölünmüştür. Eğitim verisi modelin öğrenmesi için; test verisi ise eğitilmiş modelin performansını ölçmek için kullanılmıştır. Bu bölme işlemi %70 eğitim ve %30 test oranında gerçekleştirilmiştir.

B. Makine Öğrenmesi Algoritmasının Belirlenmesi

Yapmış olduğumuz çalışma için ZeroR Algoritması, OneR Algoritması, Naive Bayes Algoritması, J48 Karar Ağacı Algoritması, Çoklu Algılayıcılar Algoritması, Destek Vektör Makinesi (DVM) Algoritması Rastgele Orman, Lojistik Regresyon ve k-NN bu algoritmalar arasında en iyi sonuç veren algoritma seçilmiştir.

ZeroR algoritması, veri madenciliğinde en basit ve en temel sınıflandırma algoritması olarak kabul edilir. Sınıflandırma problemi üzerinde hiçbir özellik kullanmaz ve sınıfları en yaygın olan sınıfa göre tahmin eder. Basit bir algoritma olmasına rağmen, modelin diğer, daha karmaşık algoritmalarla karşılaştırılması için temel bir referans sağlar. Örneğin; Bir müşteri memnuniyet anketinde, eğer anketteki en yaygın cevap "Memnun" ise, ZeroR algoritması tüm müşterileri "Memnun" olarak sınıflandırır [29].

OneR algoritması, her bir özellik için tek başına sınıflandırıcılar oluşturur ve doğruluğu en yüksek olan özelliği seçer. Bu algoritma, her özelliği kullanarak bir sınıflandırıcı oluşturur ve en iyi performansı gösteren özelliği seçer. Basit ve hızlı bir yöntem olarak bilinir. Örneğin; Bir öğrencinin sınav sonucunu tahmin ederken, eğer "Çalışma Saati" en iyi tek özelliği temsil ediyorsa, OneR bu özelliği kullanarak bir kural oluşturur. "Eğer çalışma saati 5'ten fazlaysa, geçer; aksi takdirde kalır" [30].

Naive Bayes algoritması, Bayes teoremi üzerine kurulu bir sınıflandırma yöntemidir ve sınıflar arasındaki bağımsızlık varsayımına dayanan olasılıksal bir sınıflandırma algoritmasıdır. Bu algoritmada, her bir özellik ya da girdi, diğer özelliklerle ilişkisi olmadan sınıflandırmaya etki eder. Özellikle, büyük veri setleri ve çoklu özellikler içeren problemler için etkili bir sınıflandırma yöntemidir [31].

J48 Karar Ağacı Algoritması, J48 algoritması, bir karar ağacı oluşturur ve veriyi en iyi şekilde sınıflandırmak için çeşitli karar noktaları belirler. Bu ağacın her dalı, bir sınıf tahmini yapar. J48, açık ve anlaşılır kararlar sunar. C4.5 algoritmasının bir uygulamasıdır. Ağaç yapısında, her düğüm bir özelliği temsil eder ve dallar, o özelliğin olası değerlerini gösterir [32].

Rastgele Orman (Random Forest), bir denetimli öğrenme algoritması olup sınıflandırma ve regresyon problemlerinde kullanılır. Bu algoritma, birden fazla karar ağacının bir araya gelerek oluşturduğu bir "orman" yapısıdır. Karar ağaçlarının her biri rastgele seçilen veri alt kümelerine ve özelliklere dayalı olarak eğitilir. Ortaya çıkan bu ağaçların tahminlerinin birleştirilmesiyle daha kararlı ve genellenebilir sonuçlar elde edilir. Random Forest algoritmasının amacı, tek bir karar ağacının yapısal dezavantajlarını azaltmak ve daha güçlü bir model ortaya koymaktır [33].

Çok katmanlı algılayıcılar, yapay sinir ağlarının temel yapı taşlarıdır ve birden fazla katmandan oluşurlar. Her katman, veriyi bir sonraki katmana aktararak daha karmaşık ilişkileri öğrenir. Öte yandan, ensemble learning (toplu öğrenme) yöntemleri birden fazla bağımsız modelin çıktılarını birleştirerek daha güçlü bir tahmin sistemi oluşturmayı amaçlar. Bu iki yaklaşım, farklı yapılar sunmalarına rağmen sınıflandırma performansını artırmak için kullanılabilir. [34].

K-Nearest Neighbors (KNN), denetimli öğrenme (supervised learning) algoritmalarından biridir ve sınıflandırma ile regresyon problemlerinde kullanılır. KNN algoritmasının temel prensibi, yeni bir veri noktasının sınıfını belirlemek için en yakın k komşusunun sınıflarını göz önüne alarak karar vermesidir. Algoritma, veriyi sınıflandırmak ya da tahmin yapmak için en yakın komşuları bulur ve bu komşuların özelliklerine göre yeni veri noktası için bir tahmin yapar. "K" burada dikkate alınan komşu sayısını ifade eder ve KNN algoritması bu K komşuya göre tahmin yapar [35].

Lojistik regresyon, genellikle sınıflandırma problemlerinde kullanılan bir istatistiksel modeldir. Adından "regresyon" kelimesi geçse de sınıflandırma amacıyla kullanılır ve özellikle ikili (binary) sınıflandırma problemlerinde oldukça etkilidir. Lojistik regresyon, bağımlı değişkenin iki veya daha fazla kategoriye ayrılmasını sağlar ve çıktı olarak bir olasılık değeri üretir. Bu modelde, bir olayın gerçekleşme olasılığı (örneğin, hastalık durumu) belirlenir ve kararlar bu olasılıklar üzerinden verilir [36].

Destek Vektör Makineleri(SVM), veri noktalarını iki farklı sınıfa ayırmak için mümkün olan en geniş marjı oluşturmayı hedefler. Bu algoritma, doğrusal olmayan sınıflandırmalar için Kernel yöntemleri kullanabilir. Kısaca iki sınıfı ayıran en iyi düzlemi (hiper düzlemi) bulmaya çalışır [37].

C. Değerlendirme Metrikleri

Modellerin performansları doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi yaygın kullanılan metriklerle kapsamlı şekilde değerlendirilmiştir.

D. Mobil Uygulama

Uygulama, Flutter (Dart) ile VS Code ortamında çapraz platform uyumlu şekilde geliştirilmiştir. Arayüz Flutter bileşenleriyle tasarlanmış, çevrimdışı kullanım için yerel veri önbellekleme etkinleştirilmiştir. Tüm veri yönetimi, kimlik doğrulama ve sunucu işlemleri Google Firebase altyapısı üzerinden yürütülmektedir. Sağlık verileri, Cloud Firestore veritabanında koleksiyon ve doküman yapısında saklanmakta; Firestore'un çevrimdışı önbellekleme özelliği sayesinde internet bağlantısı olmasa bile son veriler cihaza yansıtılabilmektedir.

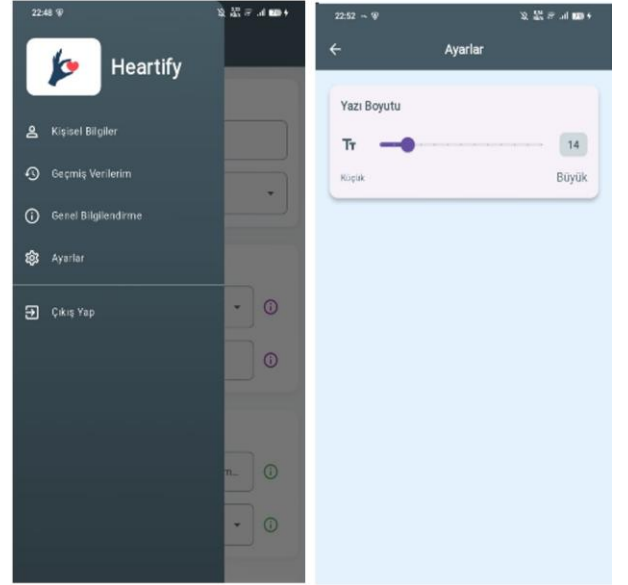
Kimlik doğrulama süreci, Firebase Authentication ile e-posta/şifre tabanlı kayıt ve giriş akışı üzerinden gerçekleştirilmektedir. Her kullanıcıya benzersiz bir kullanıcı kimliği (UID) atanmakta ve bu UID, veritabanı erişim kontrolünde kullanılmaktadır.

Güvenlik ve gizlilik kapsamında, tüm istemci-sunucu iletişimi HTTPS (TLS 1.2+) protokolü ile şifrelenmektedir. Ayrıca, veriler istirahat halinde (at rest) Google'ın varsayılan şifreleme mekanizmaları ile korunmaktadır. Bu yapı, düşük sunucu yönetimi gereksinimi ile ölçeklenebilir bir sistem sunarken, uçtan uca şifreleme ve Firebase'in yerleşik güvenlik önlemleri sayesinde kullanıcı verilerinin gizliliğini güvence altına almaktadır.

Kullanıcılar, sağlık verilerini (Bkz. Şekil 1) uygulamanın veri giriş arayüzü üzerinden girerek analiz gerçekleştirebilmektedir.

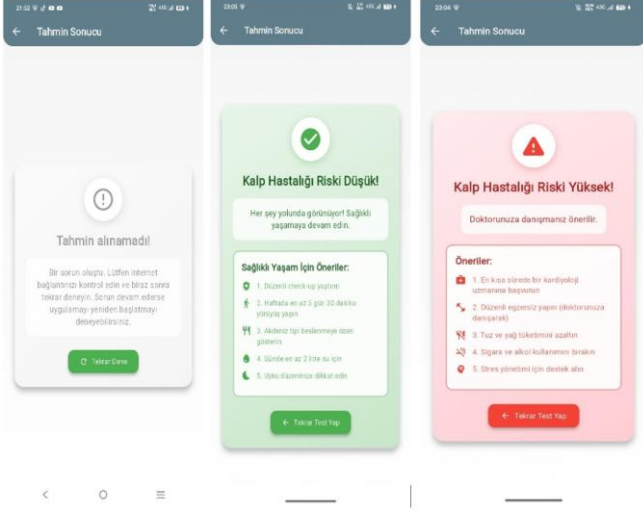
Özellikle orta yaş ve üzeri bireylerin kullanımını kolaylaştırmak amacıyla, uygulamaya yazı boyutunu artırma seçeneği eklenmiş; bu ayar, ekran tasarımını otomatik olarak uyarlama yapmaktadır (Bkz. Şekil 2).

Şekil 1. Makine Öğrenmesi Destekli Mobil Karar Destek Uygulamasının Veri Giriş Ekranları



Şekil 2. Uygulama Menüsü ve Yazı Boyutu Ayar Ekranı

Uygulama, Android platformlarında çalışacak şekilde geliştirilmiştir. Kullanıcıların girdiği veriler, makine öğrenmesi modeline entegre edilerek anlık sonuçlar elde edilmiştir. Risk analizi sonucunda, kullanıcıya kişisel sağlık durumu hakkında bilgi verilir ve gerekli durumlarda, yüksek risk taşıyan bireyler için doktora başvurmaları yönünde uyarılar yapılır (Bkz. Şekil 3).



Şekil 3. Tahmin Sonuç Ekranları

III. BULGULAR

Tablo 2’de incelenen dokuz farklı sınıflandırma algoritmasının kalp hastalığı riskini tahmin etme performans metrikleri, doğruluk, kesinlik (precision), duyarlılık (recall) ve F_1 -skor değerleri üzerinden kıyaslanmıştır (Bkz. Tablo 2).

ZeroR algoritmasında %54,95 doğruluk, %54,95 kesinlik, %100,00 duyarlılık ve %70,92 F_1 -skor. Sadece en sık görülen sınıfı (“risk taşıyan”) tahmin ettiği için tüm pozitifleri yakalarken (recall = 100%), yanlış alarm oranı (precision = 54,95%) oldukça yüksektir.

OneR algoritmasında %58,24 doğruluk, %59,68 kesinlik, %74,00 duyarlılık ve %66,07 F_1 -skor. Tek bir özelliğe dayalı basit bir kural kullanarak, pozitiflerin %74’ünü yakalarken (recall), pozitif dediği tahminlerde yaklaşık %59,7’si gerçekten doğru çıkmıştır (precision).

Tablo 2. Makine öğrenmesi modellerinin performans karşılaştırması

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
ZeroR	54,95	54,95	100,00	70,92
OneR	58,24	59,68	74,00	66,07
Naive Bayes	83,52	88,89	80,00	84,21
J48 Karar Ağacı	69,23	73,91	68,00	70,83
Rastgele Orman	82,42	84,00	84,00	84,00
Lojistik Regresyon	81,32	82,35	84,00	83,17
k-NN	86,81	88,00	88,00	88,00
Çoklu Algılayıcılar	46,15	100,0	2,00	3,92
DVM	70,33	67,16	90,00	76,92

Naive Bayes algoritmasında %83,52 doğruluk, %88,89 kesinlik, %80,00 duyarlılık ve %84,21 F_1 -skor. Özellikler arasındaki koşulsuz bağımsızlık varsayımı pratikte iyi çalışmış; pozitif tahminlerinin %88,9’u gerçek riskli vakalardan oluşurken (precision), gerçek risklilerin %80’i doğru yakalanmıştır (recall). Bu denge, yüksek bir F_1 -skoru (%84,21) ile taçlandırılmıştır.

Random Forest algoritmasında %82,42 doğruluk, %84,00 kesinlik, %84,00 duyarlılık ve %84,00 F_1 -skor. Birden fazla karar ağacını bir araya getirerek hem overfitting riskini azaltmış hem de dengeli sonuçlar üretmiştir. Pozitif dediği tahminlerin %84’ü doğru (precision) ve gerçek pozitiflerin %84’ü yakalanmıştır (recall).

Lojistik Regresyon algoritmasında %81,32 doğruluk, %82,35 kesinlik, %84,00 duyarlılık ve %83,17 F_1 -skor. Lineer bir ayırma sınırı kullanan bu model, pozitif tahminlerinin %82,35’inin doğru olmasını sağlarken (precision), pozitif vakaların %84’ünü kaçırmayarak (recall) dengeli bir F_1 -skor (%83,17) sunmuştur.

k-NN algoritmasında %86,81 doğruluk, %88,00 kesinlik, %88,00 duyarlılık ve %88,00 F_1 -skor. Komşuluk tabanlı yaklaşım, hem pozitifleri yakalamada (recall = 88%) hem de pozitif dediğinde doğrulukta (precision = 88%) en yüksek sayısal başarıyı göstermiştir. Bu da F_1 -skoru %88 ile tüm modeller arasında zirvede yer almasını sağlamıştır.

Destek Vektör Makineleri (SVM) algoritmasında %70,33 doğruluk, %67,16 kesinlik, %90,00 duyarlılık ve %76,92 F_1 -skor. Karmaşık sınırları yaklama potansiyeli sayesinde pozitiflerin %90’ını yakalamış (recall), ancak pozitif dediği tahminlerin yalnızca %67,16’sı gerçekten doğru çıkmıştır (precision). Bu durum, F_1 -skorun %76,92’de kalmasına yol açmıştır.

J48 Karar Ağacı algoritmasında %69,23 doğruluk, %73,91 kesinlik, %68,00 duyarlılık ve %70,83 F_1 -skor. Karar ağacı yapısı sayesinde hangi özelliğin hangi eşikte kullanıldığını net olarak gösterse de, pozitiflerin %68’ini yakalarken (recall) pozitif tahminlerinin %73,91’i doğru çıkmış (precision); bu da genel olarak orta düzey bir başarıya ($F_1 \approx 70,83$) tekabül etmiştir.

Çoklu Algılayıcılar algoritmasında %46,15 doğruluk, %100,00 kesinlik, %2,00 duyarlılık ve %3,92 F_1 -skor. Pozitif dediği neredeyse tüm vakalarda hata yapmıyor (precision = 100%), ancak gerçek pozitiflerin yalnızca %2’sini yakalayabiliyor (recall = 2%), bu da F_1 -skorun %3,92 gibi çok düşük bir değerde kalmasına neden olmuştur.

İncelenen dokuz algoritma arasında doğruluk, precision, recall ve F_1 -skor açısından en yüksek performans k-NN modelinde elde edilmiştir. Ancak bu modelin bazı pratik sınırlamaları nedeniyle, daha dengeli sonuçlar sunan Random Forest algoritması tercih edilmiştir.

IV. TARTIŞMA

Tablo 3’te görüldüğü üzere, literatürde en yüksek performans genellikle topluluk öğrenme temelli yöntemlere aittir (Bkz. Tablo 3).

Örneğin, Gürgen & Serttaş Random Forest ile %99 doğruluk ve %98 F_1 skoru elde ederken; Ogunpola XGBoost ile %98,50 doğruluk, %99,14 precision ve %98,29 recall, Baghdadli ise CatBoost ile %90,94 doğruluk ve %92,3 F_1 skoru raporlamıştır. Al-Alshaiikh’in ML-HDPM modeli %95,5 doğrulukla öne çıkarken, tekil modeller arasında Tschay’ın k-NN algoritması %91,99, Abdullah’ın MLP modeli %92 doğruluk sunmuştur. Bu bulgular, topluluk öğrenme modellerinin dengersiz ve çok boyutlu veri setlerinde daha tutarlı sonuçlar verdiğini göstermektedir.

Tablo 3. Literatürdeki Kalp Hastalığı Tahminine Yönelik Modellerin Karşılaştırmalı Performans Sonuçları

Yazar(lar)	En İyi Algoritma	Veri Kaynağı	Accuracy (%)
Ogunpola ve ark. [7]	XGBoost	Özel Veri	98,50
Baghdadi ve ark. [8]	CatBoost	Özel Veri	90,94
Gürgen & Serttaş [9]	Random Forest	Kaggle (Heart Failure)	99
Tschay Admassu Assegie [12]	k-NN	Kaggle (Heart Disease)	91,99
Shorewala [13]	Stacking (KNN +RF+SVM)	CVD dataset (70.000 kayıt)	75,1
Madhumita Pal ve Smita Parija arkadaşları [14]	Random Forest	Kaggle (Heart Disease)	86,9
Ch Anwar ul Hassan ve arkadaşları [15]	Gradient Boosted Trees, Çok Katmanlı Algılayıcı, Random Forest	UCI Cleveland	95
Yagyanath Rimal ve arkadaşları [16]	J48, Random Forest ve Naive Bayes	UCI Cleveland	99,24
Md. Shaheenur Islam Sumon ve arkadaşları [18]	Random Forest (CardioTabNet)	Açık Kaynaklı Veri	94,1
Al-Alshaiikh ve ark. [19]	ML-HDPM (CNN+AEHOM)	USCOM + GA Ön İşleme	95,5
Abdullah [20]	Geliştirilmiş MLP (EMLP)	CDC Heart Disease	92
Coşar & Deniz [21]	Random Forest	Örnek Veri (Türkiye)	88
Küçükmanisa & Kilimci [22]	Gradient Boosting	UCI Cleveland	95

Literatürde, topluluk öğrenme yöntemlerin özellikle Random Forest, XGBoost ve CatBoost gibi algoritmaların sınıflandırma problemlerinde genellikle üstün performans sergilediği görülmektedir. Bu çalışma da bu eğilimi destekler nitelikte bulgular sunmuştur. Test sonuçlarında k-NN algoritması %86,81 doğruluk ve %88,00 F₁-skor ile en yüksek sayısal başarıyı göstermesine rağmen, modelin yüksek riskli bireyleri sınırlı şekilde ayırt edebilmesi, mobil sağlık uygulamalarında güvenilirlik açısından bir zafiyet yaratmaktadır. Buna karşılık, Random Forest modeli %82,42 doğruluk ve %84,00 F₁-skor ile daha dengeli ve tutarlı bir performans ortaya koymuştur. Ensemble (toplu öğrenme) yapısı sayesinde aşırı öğrenme (overfitting) riskini azaltması ve karar mekanizmalarının daha açıklanabilir olması, Random Forest'ı pratik uygulamalarda öne çıkarmıştır. Ayrıca, algoritmanın mobil ortamlarda daha düşük işlem gücüyle

çalışabilmesi, uygulama performansı ve kullanıcı deneyimi açısından da avantaj sağlamaktadır.

V. SONUÇ

Bu çalışmada, kalp hastalığı riskini mobil ortamda gerçek zamanlı ve güvenilir şekilde tahmin edebilmek amacıyla dokuz farklı sınıflandırma algoritması karşılaştırılmıştır. Test sonuçlarına göre, k-NN algoritması %86,81 doğruluk ve %88,00 düzeyinde precision, recall ve F₁-skor ile en yüksek sayısal başarıyı göstermiştir. Ancak, yüksek riskli bireyleri ayırt etme konusunda sınırlı olması ve pratik uygulama zorlukları nedeniyle, daha dengeli sonuçlar sunan Random Forest modeli (%82,42 doğruluk, %84,00 precision, recall ve F₁-skor) tercih edilmiştir. Model, overfitting riskini azaltırken karar süreçlerini de daha şeffaf kılar.

Geliştirilen mobil uygulama, kullanıcıların sağlık verilerine dayalı olarak kalp hastalığı riskini hızlı ve erişilebilir biçimde değerlendirmesine olanak sağlamaktadır. Gelecek çalışmalarda, uygulamanın gerçek kullanıcılarla saha testlerinin yapılması ve sistemin hem kullanılabilirlik hem de performans açısından detaylı analiz edilmesi planlanmaktadır.

VI. TEŞEKKÜR

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2209-A-Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında 1919B012429311 proje numarası ile desteklenmiştir.

REFERENCES

- [1] "The top 10 causes of death." Accessed: Nov. 09, 2024. [Online]. Available: <https://www.who.int/en/news-room/fact-sheets/detail/the-top-10-causes-of-death>
- [2] R. Luengo-Fernandez *et al.*, "Cardiovascular disease burden due to productivity losses in European Society of Cardiology countries," *Eur Heart J Qual Care Clin Outcomes*, vol. 10, no. 1, pp. 36–44, Jan. 2024, doi: 10.1093/EHJQCCO/QCAD031.
- [3] M. Akman and S. Civek, "Dünyada ve Türkiye'de kardiyovasküler hastalıkların sıklığı ve riskin değerlendirilmesi," *The Journal of Turkish Family Physician*, vol. 13, no. 1, pp. 21–28, Mar. 2022, doi: 10.15511/TJTFP.22.00121.
- [4] "Dünyada ve Türkiye'de kardiyovasküler hastalıkların sıklığı ve riskin değerlendirilmesi - The Journal of Turkish Family Physician." Accessed: Nov. 09, 2024. [Online]. Available: <https://turkishfamilyphysician.com/makaleler/derleme/dunyada-ve-turkiyede-kardiyovaskuler-hastaliklarin-sikligi-ve-riskin-degerlendirilmesi/>
- [5] "Kalp Hastalığı Risk Faktörleri: Medcover'dan Uzman Görüşleri." Accessed: Nov. 09, 2024. [Online]. Available: <https://www.medcoverhospitals.in/tr/articles/heart-disease-risk-factors-sangamner>
- [6] "Kardiyovasküler Hastalık: Belirtileri ve Önleme İpuçları." Accessed: Nov. 09, 2024. [Online]. Available: <https://www.medcoverhospitals.in/tr/articles/cardiovascular-disease-and-its-symptoms>
- [7] A. Ogunpola, F. Saeed, S. Basurra, A. M. Albarrak, and S. N. Qasem, "Machine Learning-Based Predictive Models for Detection of Cardiovascular Diseases," *Diagnostics*, vol. 14, no. 2, Jan. 2024, doi: 10.3390/diagnostics14020144.
- [8] N. A. Baghdadi, S. M. Farghaly Abdalaliem, A. Malki, I. Gad, A. Ewis, and E. Atlam, "Advanced machine learning techniques for cardiovascular disease early detection and diagnosis," *J Big Data*, vol. 10, no. 1, Dec. 2023, doi: 10.1186/s40537-023-00817-1.
- [9] K. Yetmezli *et al.*, "Issue (28)," *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences International Indexed and Refereed*, vol. 165, no. 10, doi: 10.5281/zenodo.8238065.

- [10] R. Detrano *et al.*, “International Application of a New Probability Algorithm for the Diagnosis of Coronary Artery Disease.”
- [11] M. A. Khan *et al.*, “Optimal feature selection for heart disease prediction using modified Artificial Bee colony (M-ABC) and K-nearest neighbors (KNN).” *Sci Rep*, vol. 14, no. 1, p. 26241, Oct. 2024, doi: 10.1038/s41598-024-78021-1.
- [12] T. Admassu, “Heart disease prediction model with k-nearest neighbor algorithm,” *International Journal of Informatics and Communication Technology (IJ-ICT)*, vol. 10, p. 225, Jun. 2021, doi: 10.11591/ijict.v10i3.pp225-230.
- [13] V. Shorewala, “Early detection of coronary heart disease using ensemble techniques.” *Inform Med Unlocked*, vol. 26, Jan. 2021, doi: 10.1016/j.imu.2021.100655.
- [14] M. Pal and S. Parija, “Prediction of Heart Diseases using Random Forest,” *J Phys Conf Ser*, vol. 1817, p. 12009, Jun. 2021, doi: 10.1088/1742-6596/1817/1/012009.
- [15] C. A. ul Hassan *et al.*, “Effectively Predicting the Presence of Coronary Heart Disease Using Machine Learning Classifiers,” *Sensors*, vol. 22, no. 19, Oct. 2022, doi: 10.3390/s22197227.
- [16] Y. Rimal, N. Sharma, S. Paudel, A. Alsadoon, M. P. Koirala, and S. Gill, “Comparative analysis of heart disease prediction using logistic regression, SVM, KNN, and random forest with cross-validation for improved accuracy,” *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-93675-1.
- [17] A. Alariyibi, M. El-Jarai, and A. Maatuk, “Evaluating the Accuracy of Classification Algorithms for Detecting Heart Disease Risk,” *Machine Learning and Applications: An International Journal*, vol. 10, no. 4, pp. 01–12, Dec. 2023, doi: 10.5121/mlaij.2023.10401.
- [18] M. Shaheenur Islam Sumon *et al.*, “CardioTabNet: A Novel Hybrid Transformer Model for Heart Disease Prediction using Tabular Medical Data.”
- [19] H. A. Al-Alshaikh *et al.*, “Comprehensive evaluation and performance analysis of machine learning in heart disease prediction,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-58489-7.
- [20] M. Abdullah, “Artificial intelligence-based framework for early detection of heart disease using enhanced multilayer perceptron,” *Front Artif Intell*, vol. 7, 2024, doi: 10.3389/fraci.2024.1539588.
- [21] M. COŞAR and E. DENİZ, “Makine Öğrenimi Algoritmaları Kullanarak Kalp Hastalıklarının Tespit Edilmesi,” *European Journal of Science and Technology*, Oct. 2021, doi: 10.31590/ejosat.1012986.
- [22] A. KÜÇÜKMANİSA and Z. H. KİLİMCİ, “Heart Disease Prediction with Machine Learning-Based Approaches,” *Sakarya University Journal of Science*, Nov. 2023, doi: 10.16984/saufenbilder.1312109.
- [23] “Kalp Damar Sağlığı Bilgilendirme Portalı - Turkish Society of Cardiology.” Accessed: Nov. 09, 2024. [Online]. Available: <https://tkd.org.tr/kardiyobil/kalp-damar-sagligi/kardiyovaskuler-risk-hesaplama>
- [24] “Kalp Hastalığı Riski Hesaplayıcı - Memorial.” Accessed: Nov. 09, 2024. [Online]. Available: <https://www.memorial.com.tr/bilgi/kalp-hastaligi-risk-hesaplayici>
- [25] “Cardiovascular Risk Calculator App - PAHO/WHO | Pan American Health Organization.” Accessed: Nov. 09, 2024. [Online]. Available: <https://www.paho.org/en/hearts-americas/cardiovascular-risk-calculator-app>
- [26] “ASCVD Risk Estimator +.” Accessed: Nov. 09, 2024. [Online]. Available: <https://tools.acc.org/ASCVD-Risk-Estimator-Plus#!/calculate/estimate/>
- [27] “2018 Prevention Guidelines Tool CV Risk Calculator.” Accessed: Nov. 09, 2024. [Online]. Available: <https://static.heart.org/riskcalc/app/index.html#!/baseline-risk>
- [28] “Heart Disease.” Accessed: Nov. 09, 2024. [Online]. Available: <https://www.kaggle.com/datasets/data855/heart-disease/data>
- [29] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. Witten, “The WEKA data mining software: An update,” *SIGKDD Explor. Newsl.*, vol. 11, pp. 10–18, May 2008.
- [30] Y. Kaya and R. Tekin, “Comparison of discretization methods for classifier decision trees and decision rules on medical data sets,” *Avrupa Bilim ve Teknoloji Dergisi*, no. 35, pp. 275–281, 2022, doi: 10.31590/ejosat.1080098.
- [31] I. Rish, “An Empirical Study of the Naïve Bayes Classifier,” *IJCAI 2001 Work Empir Methods Artif Intell*, vol. 3, May 2001.
- [32] by J. Ross Quinlan, M. Kaufmann Publishers, and S. L. Salzberg, “Programs for Machine Learning,” 1994.
- [33] L. Breiman, “Random Forests,” 2001.
- [34] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain [J],” *Psychol. Review*, vol. 65, pp. 386–408, May 1958, doi: 10.1037/h0042519.
- [35] T. Cover and P. Hart, “Nearest neighbor pattern classification,” *IEEE Trans Inf Theory*, vol. 13, no. 1, pp. 21–27, 1967, doi: 10.1109/TIT.1967.1053964.
- [36] “logistic”.
- [37] C. J. C. Burges, “A Tutorial on Support Vector Machines for Pattern Recognition.”