



KALP HASTALIĞI TEŞHİSİNDE YAPAY ZEKÂ YÖNTEMLERİNİN KULLANIMI VE KARŞILAŞTIRILMASI

¹Onur ÜNLÜ , ²Hüma ÜNLÜ , ³Yılmaz ATAY 

¹Tarsus Üniversitesi, Tarsus Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Mersin, TÜRKİYE

²Aksaray Üniversitesi, Bilgi İşlem Daire Başkanlığı, Aksaray, TÜRKİYE

³Gazi Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara, TÜRKİYE

¹onurunlu@tarsus.edu.tr, ²humaunlu@aksaray.edu.tr, ³yilmazatay@gazi.edu.tr

(Geliş/Received: 01.08.2021; Kabul/Accepted in Revised Form: 19.04.2022)

ÖZ: Günümüzde insan ölümlerinin önemli bir kısmı kalp hastalıkları kaynaklıdır. Bu tür hastalıklar erken teşhis ile tedavi edildiğinde belirtilen ölüm oranları ciddi bir şekilde azalabilmektedir. Bu çalışmada Cleveland ve Z-Alizadehsani veri kümeleri için yapay zeka teknikleriyle kalp hastalığı teşhisi uygulamaları gerçekleştirilmiştir. Cleveland veri kümesi için yaş, cinsiyet, göğüs ağrı türü, kan basıncı, kolesterol, kan şekeri, elektrokardiyografi sonucu, en yüksek kalp atış hızı, indüklenen göğüs ağrısı, eski zirve, eğitim, majör damar sayısı, tal isimleriyle ifade edilen 13 özellik yapay zeka tabanlı erken teşhis sistemine girdi özellikler olarak verilmiştir. Z-Alizadehsani veri kümesi için ise veritabanında bulunan 55 özelliğin tamamı aynı yapay zeka sistemine girdi özellik olarak kullanılmıştır. Önerilen yapay zeka sisteminde Naive-Bayes, Lineer Regresyon, Polinomiyal Regresyon, Destek Vektör Makinası (DVM) gibi basit sınıflandırıcıların yanı sıra bir topluluk sınıflandırma yaklaşımı olan Rassal Orman ve Yapay Sinir Ağı tabanlı Çok Katmanlı Algılayıcı (ÇKA) kullanılmıştır. Yapılan deneylerde 10 K katlama ve Bekletme (20 çalıştırma) çapraz doğrulama yöntemleri kullanılmıştır. Çoklu Lineer Regresyon yaklaşımı bekletme yöntemiyle Cleveland veri kümesi için 0.90'a kadar doğruluk değeri üretirken Z-Alizadehsani veri kümesi için 0.91'e kadar doğruluk değeri üretmiştir. K katlama çapraz doğrulama yöntemi uygulandığında ise bu değerler iki veri kümesi için de 0.93'e kadar doğruluk oranına ulaşmıştır. DVM yöntemi Cleveland veri kümesi için K katlama yöntemiyle 0.97 doğruluk oranıyla en yüksek sonucu vermiştir. Genel olarak K katlama yönteminin Bekletme yöntemine göre daha başarılı sonuçlar ürettiği gözlemlenmiştir. Deneylerin detaylı sonuçları ve literatürde yapılan çalışmalarla karşılaştırmalı sonuçları çizelgelerde verilmiştir. Çalışmada kullanılan modeller Türkiye'deki hastane otomasyonları gibi sistemlere entegre edilerek hastalıkların erken ve doğru teşhis edilmesi sağlanabilecektir. Önerilen sistem, ideale yakın bir düzeyde geliştirildiğinde sürekli öğrenen bir web servis olarak hastanelerin otomasyon sistemlerine sunulabilecektir.

Anahtar Kelimeler: Kalp hastalığı teşhisi, Çok katmanlı algılayıcı, Lineer regresyon, Polinomiyal Regresyon, Destek Vektör Makinası, Rassal Orman, Naive-Bayes, Sınıflandırma, Tanıma

The Utilization and Comparison of Artificial Intelligence Methods in the Diagnosis of Cardiac Disease

ABSTRACT: Today a significant amount of human mortality is because of cardiac disease. These mortality could be reduced considerably by diagnosis on early stages. In this study we propose an artificial intelligence based early diagnosis system for cardiac disease prediction. For the research we utilized Cleveland and Z-Alizadehsani datasets. For Cleveland database which contains 76 attributes, 13 attributes selected in order to predict heart disease presence. For Z-Alizadehsani database which contains 55 attributes, all attributes are utilized for prediction. System implements not only basic classifiers as Naive-Bayes, Linear Regression, Polynomial Regression, Support Vector Machine (SVM)

but also ensemble classifier Random Forest and complex models like artificial neural network based multilayer perceptron. On cardiac disease prediction two cross validation techniques employed. Firstly 20 experiments processed for each method by utilizing holdout cross validation technique. Secondly K-fold (10 fold) cross validation is applied for all methods. Multiple Linear Regression with holdout cross validation has achieved best results as 0.91 accuracy for Cleveland dataset and 0.91 for Z-Alizadehsani dataset. For these two datasets when K fold is utilized 0.93 accuracy score achieved for both. Best result is obtained as 0.97 accuracy by SVM method with Z-Alizadehsani dataset. Generally it is observed that K fold method has better results than Holdout method. Detailed and comparable results of experiments are given in tables. Illnesses could be detected correctly in early phases by integrating these models to health systems like hospital otomations. The proposed system could be presented as continous learning web service to health automation systems.

Keywords: *Cardiac disease prediction, Multilayer perceptron, Linear regression, Polynomial Regression, Support Vector Machine, Random Forest, Naive-Bayes, Classification, Recognition*

GİRİŞ (INTRODUCTION)

Yapay zeka yöntemleri insan zekasını modelleyerek, birçok iş sahasında insan işgücünün yerini almakta veya insanlara yardımcı olarak ilgili sektörlerde kullanılmaktadır. Bu tür mekanizmalar; ses tanıma, görüntü işleme, otonom araçlar, ekonomi piyasalarında gelecek tahminleme, siber güvenlikte saldırı tespit sistemleri, yazılım geliştirmede maliyet kestirimi, sağlık sektöründe hastalıkların teşhisi gibi pek çok alanda kullanılmaktadır.

Ülkemizde her yıl binlerce insan kalp hastalığından yaşamını yitirmektedir (TÜİK, 2019). Kalp hastalıkları insan sağlığını tehdit eden en önemli faktörlerden biri haline gelmiştir. Kalp hastalığının pek çok sebebi olabilir. Bunlar arasında kan damar hastalıkları, koroner damar hastalıkları, kalp ritim bozuklukları, doğuştan gelen hastalıklar ve benzeri olabilir. Bu makalede ifade edilen kalp hastalığı terimi herhangi bir türdeki kalp hastalığının mevcudiyetini ifade etmektedir.

Yapay zeka yöntemleri en temel anlamda danışmanlı (Kotsiantis ve diğ., 2007) ve danışmansız (Ghahramani, 2003) olmak üzere 2 ana grup altında ele alınabilir. Danışmanlı öğrenme yöntemlerinde girdi ve çıktı veriler elde bulunur ve bunlar sisteme birlikte verilerek sistemin eğitilmesi sağlanır. Sistem bu eğitimin sonucunda öğrenir ve test girdileriyle test edilir. Test girdilerinin gerçek çıktıları elde olduğundan sistemin çıktılarıyla karşılaştırılarak sistemin başarımları ölçümlenir. Danışmansız öğrenme teknikleri ise çıktı verilerinin elde bulunmadığı durumlarda kullanılırlar. Bu sistemler verilerin birbirlerine olan benzerliklerini çeşitli mesafe ölçme yöntemleriyle karşılaştırarak verileri gruplara ayırırlar. Bu makalede danışmanlı öğrenme teknikleri kalp hastalığı teşhisinde kullanılmış ve yöntemlerin başarımları birbirleriyle karşılaştırılmıştır.

LİTERATÜR ÇALIŞMASI (LITERATURE REVIEW)

Literatürde kalp hastalığı teşhisinde yapay zeka kullanan pek çok çalışma mevcuttur. Zhenya ve Zhang 2021 yılında yayınlanan çalışmalarında kalp hastalığı teşhisinin verimliliğini arttıran ve yanlış sınıflandırma maliyetini düşüren 5 adet heterojen yöntem önermişlerdir (Qi ve Zuru, 2021). Bu yöntemde Rassal Orman, Lojistik Regresyon, DVM, Aşırı Öğrenme Makinası ve K en yakın komşu algoritmaları kullanılmıştır. Önerilen algoritma topluluğunun birlikte kullanılması sonucunda tekil sınıflandırıcılara göre daha yüksek başarımlar elde etmişlerdir. Sonuçların değerlendirilmesinde kesinlik (precision), duyarlılık (recall), özgüllük (specificity) gibi metrikler kullanılmıştır.

Yar ve diğerleri (2020), araştırmalarında 10 adet farklı yapay zeka sınıflandırma algoritmasını Cleveland ve Hungarian veri kümeleri üzerinde çalıştırmışlar ve 0.90'ın üzerinde doğruluk performansı elde etmişlerdir.

Arabasadi ve diğerleri (2017), Z-Alizadeh Sani (Alizadehsani ve diğ., 2013) veri kümesi üzerinde çalışmalar yapmışlardır. Öznitelik seçimi için DVM'ye göre ağırlık skoru kullanılmış, en yüksek skoru elde eden öznitelikler eğitime dâhil edilmiştir. Giriş katmanında başlangıç değerlerinin genetik algoritma ile hesaplandığı, üst katmanda ÇKA bulunan hibrit bir yöntem ile 0.97 duyarlılık, negatif olarak doğru etiketlenen verilerin gerçekte negatif olan verilere oranı ile bulunan 0.92 özgüllük değeri elde edilmiştir. Alizadehsani ve diğerleri (2013), Z- Alizadehsani veri kümesi üzerinde Sıralı Minimal Optimizasyon (SMO), Naive Bayes ve ÇKA yöntemleri ile sırasıyla 0.94, 0.76 ve 0.88 doğruluk değerleri elde etmiştir. SMO DVM'lerinin eğitimi sırasında ortaya çıkan optimizasyon problemini verimli bir şekilde çözmektedir.

Mohanad Alkhodari, Luay Fraiwan tarafından gerçekleştirilen başka bir çalışmada konvolüsyonel ve tekrarlayan sinir ağları kullanılarak fonokardiyogram kayıtları üzerinden kalp kapakçığı hastalığı tespiti yapılmıştır (Alkhodari ve Fraiwan, 2021). Veriler 1000 adet kayıttan oluşmaktadır. Normal hastalar ve 4 farklı kalp kapakçığı hastalığı için ayrı ayrı 200 kayıt bulunmaktadır. Giriş katmanında CNN sinyal verilerini alıp işlemekte BiLSTM (Bidirectional Long Short Term Memory – İki Yönlü Uzun Kısa Süreli Hafıza) katmanına girdi olarak göndermektedir. LSTM gelişmiş bir tür TSA (Tekrarlı Sinir Ağı)'dır. Sonuçta 0.98 kesinlik, hassasiyet ve F1-ölçütü değerleri elde edilmiştir.

Isparta Uygulamalı Bilimler Üniversitesi akademisyenlerinin gerçekleştirdiği bir çalışmada Parçacık Sürü Optimizasyonu (PSO) yöntemiyle Cleveland veri kümesi üzerinde özellik seçimi yapılmış ve Rassal Orman algoritmasıyla eğitim gerçekleştirilmiştir. Bu eğitim sonucunda test verileriyle yapılan testten 0.85-0.88 aralığında doğruluk, özgüllük, duyarlılık, kesinlik ve F-ölçütü değerleri elde edilmiştir (Ekrem ve diğ., 2020).

Nancy Masih ve arkadaşları kalp hastalığının teşhisinde Framingham veri kümesi üzerinde ÇKA tabanlı Derin Sinir Ağı kullanmışlar ve çeşitli veri önışleme teknikleriyle önceki çalışmalara göre 0.036 oranında başarıyı arttırarak 0.96 seviyesinde doğruluk oranına ulaşmışlardır. Kullandıkları sinir ağı girdi katmanı, çıktı katmanı ve birden fazla gizli katmandan oluşmaktadır (Masih ve diğ., 2021).

Akalın ve diğerleri (2020), K en yakın komşu, Gaussian Naive Bayes ve Rassal Orman algoritmaları ile sınıflandırma yapmış ve Cleveland veri kümesi üzerinde Rassal Orman ile 0.82 doğruluk elde etmişlerdir. Chen ve diğerleri (2011) problemi yapay sinir ağları ile çözümlenmişler ve 0.80 doğruluk değerine aynı veri kümesi için ulaşmışlardır. Mohan ve diğerleri (2019), tarafından yine aynı veri kümesi üzerinde lineer modellenmiş hibrit Rassal Orman sistemini önermiş ve 0.88 doğruluk değeri elde etmişlerdir.

Hsieh ve diğerleri (2012), Endovasküler anevrizma onarımı (EVAR) ameliyatı geçiren hastanın ameliyat sonrası komplikasyon oluşma riskini ve ikincil değişken olarak komplikasyon türünü tahmin etmeye çalışan Bayes Ağı, Yapay Sinir Ağı ve DVM'nin birleştirilmesi ile oluşan yeni bir birleştirilmiş model önermiştir. Öznal, belirsiz veya yetersiz tanımlanmış değişkenler eğitime dahil edilmemiştir. Önerilen algoritma ile 0.81 oranında doğruluk elde edilmiştir.

Shorewala (2021) tarafından gerçekleştirilen çalışmada yoğun sinir ağı kullanılarak 70.000 kayıt içeren 'Cardiovascular Disease Dataset' veri kümesi üzerinde çalışılmıştır. Önerilen mimaride üç gizli katman bulunmaktadır. Birinci katmanda 256 nöron bulunmaktadır ve aktivasyon fonksiyonu olarak sigmoid kullanılmıştır. İkinci katmanda 256 nöron bulunmaktadır ve aktivasyon fonksiyonu olarak softmax kullanılmıştır. Son gizli katman birinci katmanla aynı özelliكتedir. Mimariyle 0.739 doğruluk ve 0.72 F₁ skoru elde edilmiştir.

Dutta ve diğerleri (2020) tarafından geliştirilen iki katmanlı evrışimsel sinir ağı (ESA) sonuç sınıfı özel uyum dengesizliğine karşı dirençlidir. Model 1999-2016 yılları arasında elde edilmiş 37079 kayıt içeren NHANES veri kümesi üzerinde çalışmaktadır. Çalışmadaki en yüksek doğruluk oranı 0.82'dir.

Ayon ve diğerleri (2020), sınıflandırma tabanlı yöntemler ve derin öğrenme yöntemini kullanarak Cleveland veri kümesi üzerinde karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Bu çalışmada DVM, Lojistik Regresyon, Derin Sinir Ağı, Karar Ağacı, Naive Bayes, Rassal Orman, K-En Yakın Komşu algoritmaları karşılaştırılmıştır. Derin Sinir Ağı 4 gizli katman için her bir katmanda sırasıyla 14, 16, 16,

14 nöron olacak şekilde tasarlanmıştır. Çalışmalarında Cleveland veri kümesi için en yüksek başarıyı 0.97 ile DVM yöntemi vermiştir.

Kolukisa ve diğerleri (2019) tarafından gerçekleştirilen çalışmada Cleveland ve Z-Alizadehsani veri kümeleri üzerinde önceden yapılmış çalışmalar karşılaştırılmış ve çizelge halinde sunulmuştur. Ayrıca Naive-Bayes, Rassel Orman, K-En Yakın Komşu, ÇKA, DVM sınıflandırıcıları ayrı ayrı ve toplu olarak test edilmiştir. Medikal doktorların önerisiyle Cleveland veri kümesi üzerinde yapılan özellik seçimi sonucunda 0.82 doğruluk oranına ulaşmışlardır. Z-Alizadehsani veri kümesi üzerinde Fisher Diskriminant Analizi ile oluşturulmuş toplu sınıflandırma metodu 0.94 F_1 skor değerine ulaşmıştır.

Mienye ve diğerleri (2020) tarafından Cleveland ve Framingham veri kümeleri rasgele daha küçük parçalara ayrılıp sonrasında Sınıflandırma ve Regresyon Ağacı (SRA) ile modellenmiştir. Algoritma sonraki adımda Ağırlıklı Yaşlandırma Sınıflandırıcı Topluluğunun (AYST) bir modifikasyonu olan doğruluk tabanlı bir yaklaşım kullanarak farklı SRA modellerinden homojen bir topluluk modeli oluşturur. Doğruluğuna ve toplulukta harcanan zamana bağlı olarak sınıflandırıcılara ağırlıklar atanır. Ağırlığı belirli bir eşliğin altına düşen sınıflandırıcı topluluktan çıkarılır. Model Cleveland ve Framingham veri kümeleri üzerinde sırasıyla 0.93 - 0.91 doğruluk değerlerine ulaşmıştır.

Gupta ve diğerleri (2021), Rassel Orman, DVM ve Lojistik Regresyon modellerini birlikte kullanarak bir topluluk modeli oluşturmuştur. Bu model Z-Alizadeh Sani Veri Kümesini Kullanarak Kalp Hastalığı Teşhisi için DMHZ (çeşitli yöntemlerin birlikte uygulanması) olarak isimlendirilmiştir. Model 0.95 doğruluk, 0.98 duyarlılık değeri elde etmiştir.

VERİ KÜMELERİ (DATA SETS)

Bu çalışmada deneyler iki farklı veri kümesi kullanılarak gerçekleştirilmiştir. Bunlardan birincisi yapay zeka ile kalp hastalığı teşhisi uygulamalarında uzun zamandan beri yoğun olarak kullanılmakta olan UCI veri merkezinde yayınlanmış Cleveland veri kümesini içermektedir (Janosi ve diğ., 1988). Cleveland veri kümesi 167 kalp hastalığı bulunmayan ve 136 kalp hastalığı bulunan toplam 303 tekil kayıt içermektedir. Bunlardan 6 kayıt için eksik veri bulunmaktadır. Bu veriler veri kümesinden ön işleme aşamasında çıkarılarak 297 veri ile çalışma gerçekleştirilmiştir. Veri kümesi toplamda 76 özellik barındırmasına karşın bunlardan kalp hastalığı teşhisinde sıklıkla kullanılan 13 özellik yapay zeka sistemine girdi olarak verilmiştir. Kalp hastalığı teşhisinde kullanılan 13 girdi özellik Çizelge 1' deki gibidir. Hastaların adları ve sosyal güvenlik numaraları kişisel verilerin korunması amacıyla veri tabanından çıkarılmıştır.

Bu çalışmada yapay zeka ile kalp hastalığı teşhisi sistemi için kullanılan ikinci veri kümesi 2017 yılında yayınlanan Z-Alizadehsani veri kümesidir (Alizadehsani ve diğ., 2017). Z-Alizadehsani veri kümesi 216 kalp hastalığı bulunan ve 87 kalp hastalığı bulunmayan olmak üzere toplam 303 adet kayıt içermektedir. Veritabanında her bir kayıt için 55 farklı özellik bulunmaktadır. Özellikler; demografik, semptom ve muayene, EKG sonuçları, labaratuvar ve eko sonuçları olmak üzere 4 farklı alana aittir. Özelliklerden bazıları şu şekildedir: hipertansiyon geçmişi, mevcut sigara içen kişi, eskiden sigara içen kişi, birinci derece yakınarda kalp hastalığı mevcudiyeti, kan basıncı, ritim, kan şekeri, hemoglobinin. Alanların bazıları var veya yok şeklinde ikili değerler içerirken bazıları sayısal ölçüm sonuçlarını içermektedir. Z-Alizadehsani veri kümesinde bulunan 55 özelliğin tamamı uygulanan deneylerde kullanılmıştır.

Çizelge 1. Kalp Hastalığı Teşhisinde Yapay Zekaya Girdi Olarak Kullanılan 13 Özellik*Table 1. 13 Attributes Which Are Used As Input To Artificial Intelligence For Heart Disease Diagnosis*

Yaş	Age
Cinsiyet	Sex
Göğüs ağrı türü	Chest pain type (4 values)
Kan basıncı	Resting blood pressure
Kolesterol	Serum cholesterol in mg/dl
Kan şekeri	Fasting blood sugar > 120 mg/dl
Elektrokardiyografik sonucu	Resting electrocardiographic results (values 0,1,2)
En yüksek kalp atış hızı	Maximum heart rate achieved
İndüklenen göğüs ağrısı	Exercise induced angina
Eski zirve	Old peak = ST depression induced by exercise relative to rest
Eğim	The slope of the peak exercise ST segment
Majör damar sayısı	Number of major vessels (0-3) colored by fluoroscopy
Tal	Thal: 0 = normal; 1 = fixed defect; 2 = reversable defect

DANIŞMANLI YAPAY ZEKA VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ (SUPERVISED ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING TECHNIQUES)


UCI ve Kaggle gibi veri depolarında çeşitli hastalıklar için derlenmiş hasta kayıtları bulunan veri kümeleri bulunmaktadır. Bu makalede kalp hastalığı teşhisi için derlenip UCI veri deposunda sunulmuş Cleveland ve Z-Alizadehsani veri kümeleri için temel makine öğrenmesi yöntemleri, Rassel Orman topluluk sınıflandırma yöntemi ve ÇKA kullanılmıştır. Bu bölümde kullanılan yöntemlerin detayları anlatılmaktadır.

Regresyon (Regression)

Lineer Regresyon (Seber ve Lee, 2012), verilen x_i bağımsız değişkenleri ve y bağımlı değişkenlerine göre x_i bağımsız değişkenlerinin katsayılarını (w_i) ve sabit değerini (w_0), ϵ (epsilon) hata payıyla bulmaktadır. Lineer regresyon verilen noktalara göre mesafelerin en az olacağı şekilde en uygun çizgiyi bulur. Regresyon süreçlerinin tekli lineer regresyon, çoklu lineer regresyon, polinomial regresyon gibi farklı türleri vardır.


Tekli lineer regresyonun formülü $y = w_0 + w_1x$ şeklindedir. Burada y bağımlı değişkeni tek bir adet x bağımsız değişkenine bağlıdır. Şekil 1' de örnek olarak verilen x ve y değerlerine göre tekli lineer regresyonda mavi çizgiyle gösterilen doğru çizilmiştir. Bundan sonra tahmin amacıyla gelecek olan yeni x değerleri doğru üzerindeki y karşılıklarına göre tahminlenecek ve belirli bir hata payıyla y değerleri tahmin edilmiş olacaktır.

Çoklu lineer regresyonun (Tabachnick ve diğ., 2007) formülü $y = w_0 + w_1x_1 + w_2x_2 + w_3x_3 + \dots$ şeklindedir. Burada y bağımlı değişkeni girdi olarak kullanılan n adet x_i bağımsız değişkenine bağlıdır. Çoklu lineer regresyonda hangi x_i değerlerinin katsayısının daha önemli olduğunu bulmak için adım adım regresyon uygulanır. Burada tüm değişkenler için Sıradan En Küçük Kareler (SEKK) hesabı yapılır ve P değerlerine bakılarak oransal olarak yüksek olan x_i değerleri teker teker regresyon hesabından çıkarılarak y bağımsız değişkeni üzerinde en etkili x_i değerleri bulunur ve kullanılır. $y = w_1x_1 + w_2x_2$ tipinde bir çoklu lineer regresyona ait örnek grafik Şekil 2' de verilmiştir.



Şekil 1. Tekli Lineer Regresyon Örneği

Figure 1. Single Linear Regression Example




Şekil 2. Çoklu(İkili) Lineer Regresyon Örneği

Figure 2. Multiple (Double) Linear Regression Example

Çoklu regresyon, polinomial regresyon denilen bir yöntemi de içermektedir. Polinomial regresyonda (Ostertagova, 2012) bağımlı değişkenler bağımsız değişkenlerin üsleri şeklinde ifade edilmektedir. Polinomial regresyonun formülü $y = w_0 + w_1x_1 + w_2x_2^2 + w_3x_3^3 + \dots + w_ix_i^i$ şeklindedir.

Destek Vektör Makinası (Support Vector Machine)

Destek Vektör Makinaları (Cristianini ve Shawe-Taylor, 2000) sınıflandırma için kullanılan başarılı bir makine öğrenmesi algoritmasıdır. Algoritma özelliklere göre verileri sınıflar arasında maksimum boşluk oluşacak şekilde bir alan belirler. Bu alanlar oluşturulurken her iki sınıfın sınırlarını oluşturan örneklerden geçecek şekilde Şekil 3' teki gibi destek vektörleri çizilir. Bu destek vektörleri lineer bir fonksiyon kullanılarak çizilebildiği gibi, polinomial, gauss veya üssel bir fonksiyon kullanılarak çizilebilir. Kullanılan veri kümesi dağınık bir yapıda ise çekirdek fonksiyonları kullanılarak üçüncü bir boyut oluşturulup veriler sınıflandırılabilir. Kullanılacak çekirdek fonksiyonu radyal tabanlı, lineer, polinomial veya sigmoid olabilmektedir.



Şekil 3. Destek Vektör Makinası

Figure 3. Support Vector Machine

$y = wx + b$ doğrusu için $y_i - wx_i - b \leq \epsilon$ ve $w x_i + b - y_i \leq \epsilon$ eşitsizlikleri ile sınıfların sınırları belirlenmektedir.

Rassal Orman (Random Forest)

Karar ağaçları (Safavian ve Landgrebe, 1991) kullanılarak geliştirilmiş Rassal Orman (Oshiro ve diğ., 2012) sınıflandırma algoritması veri kümesini rasgele parçalara ayırıp her bir parça için ayrı ayrı karar ağaçları oluşturmaktadır. Her eğitim seti, orijinal eğitim setinden değiştirilir ve seçilen rastgele nitelikler üzerindeki en iyi bölünme kullanılarak düğüm bölünür. Oluşturulan karar ağaçlarından üretilen sonuç değerleri çoğunluk oylaması ile puanlandıktan sonra en yüksek puanı alan sonuç sınıfa ulaşılmaktadır. Karar ağaçlarının yaprak düğümlerinde sınıflar bulunmaktadır. Veri kümesini parçalara böldüğü için büyük veri kümelerinde hızlı ve hesaplama açısından verimli çalışabilmektedir.

Naive Bayes (Naive Bayes)

Naive Bayes algoritması Bayes teoremine (Smets, 1993) dayanmaktadır. Bayes teoremi koşullu olasılığa bağlı olarak hesaplanır. X ve Y koşulunun birlikte gerçekleştiği alan olan kesişim kümesi X kesişim Y dir. Yani hem daha geniş bir küme olan Y olasılığının gerçekleşip aynı zamanda X olasılığının gerçekleşme ihtimali:

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (1)$$

(1) olarak hesaplanır. Naive Bayes (Friedman ve diğ., 1997) sınıflandırma algoritması ise her bir bağımlı değişken için ayrı ayrı her durumun olasılığını hesaplar. Algoritma temel olarak her bir özelliğin belirli dağılımından ziyade modeldeki güçlü bağımsızlık varsayımlarını ifade eder. Modelde her bir bağımlı değişken için olasılık hesaplandığından Linear Regresyondan genellikle daha iyi sonuç üretir. İki özellik x_1 ve x_2 için $P(x_1, x_2) = P(x_1) P(x_2)$ özelliklerinin olasılık değerlerinin çarpımı ile bulunur. X bağımlı değişkenleri $X = (x_1, x_2, x_3, \dots, x_n)$ olmak üzere y olasılığı:

$$P(y|x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(x_1)P(x_2) \dots P(x_n)} \quad (2)$$

ile hesaplanır. Belirli bir girdi için payda sabit terim olduğundan kaldırılır ve

$$P(y|x_1, \dots, x_n) \propto P(y) \prod_{i=1}^n P(x_i|y) \quad (3)$$

olarak elde edilir. Bir sınıflandırıcı model oluşturmak için çıktı değerlerinin en büyük değeri alınır. Sonuç olarak y çıktısı

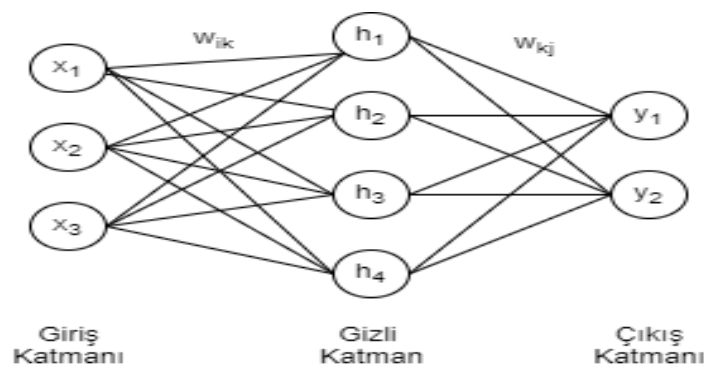
$$y = \operatorname{argmax}_y P(y) \prod_{i=1}^n P(x_i|y) \quad (4)$$

formülü ile hesaplanır. Denetimli sınıflandırma algoritması olan Naive Bayes'in Çok Terimli Naive Bayes (Kibriya ve diğ., 2004), Bernoulli Naive Bayes (Raschka, 2014) ve Gaussian Naive Bayes (Fadlil ve diğ., 2017) türleri vardır. Çok terimli Naive Bayes, her özelliği çok terimli bir dağılım olarak ifade eder. Bernoulli Naive Bayes'te özellikler ikili değişkenlerden oluşan vektör olarak ifade edilir. Gaussian Naive Bayes'te ise her özelliği bir Gauss (normal) dağılımına uygun olarak oluşturur.

Yapay Sinir Ağları (Artificial Neural Networks)

Yapay Sinir Ağları ilk olarak Rosenblatt (1958) tarafından beyindeki sinir hücresinin matematiksel olarak modellenmesi olan algılayıcı (perceptron) kavramının ortaya atılmasıyla gündeme gelmiştir (Jain ve diğ., 1996). Bu kavramda sinir hücresi çeşitli giriş bağlantılarına ve bağlantı ağırlıklarına sahipken bir adet çıktı bağlantısına sahiptir.

Algılayıcıda giriş X_i değerleri W_i ağırlıklarıyla çarpılarak bunların toplamı eğer eşik değerinin üzerindeyse 1 altındaysa 0 çıktısını verir. Bu şekilde danışmanlı öğrenme yönteminde ağırlıkların beklenen çıktı ile gerçek çıktı aynı ise değişiklik yapılmaz. Eğer ağırlıkların gerçek çıktı beklenen çıktıdan büyükse ilgili ağırlık değeri öğrenme katsayısının ilgili X değeriyle çarpımı miktarınca azaltılır ($W_i = W_{i \text{ eski}} - \lambda X_i$). Eğer ağırlıkların gerçek çıktı beklenen çıktıdan küçükse ilgili ağırlık değeri öğrenme katsayısının ilgili X değeriyle çarpımı miktarınca artırılır ($W_i = W_{i \text{ eski}} + \lambda X_i$). Bir değişken ağırlığının değişimi iterasyon olarak adlandırılırken tüm değişkenlerin ağırlıklarının değişimi epok olarak adlandırılır. ÇKA ölçümlenebilir fonksiyonlara yakınsamak üzere eğitilen ileri beslemeli yapay sinir ağlarından (Hornik ve diğ., 1989). Öğrenmesini geri yayılım algoritmasıyla gerçekleştirir. ÇKA'lar giriş katmanı, gizli katman ve çıkış katmanı olmak üzere en az üç katmandan oluşmaktadır. Girdi ve çıktı katmanlarındaki nöron sayısını problemdeki girdi ve çıktı değişkenleri belirlerken, gizli katman sayısı ve gizli katmanlardaki nöron sayısı daha ziyade sistemin performansını etkileyen unsurlardır. Her bir gizli katman değeri $h_k = \sum_i w_{ik} x_i$ ile hesaplanır. Şekil 4' te ÇKA mimarisi görülmektedir.



Şekil 4. Çok Katmanlı Algılayıcı

Figure 4. Multi Layer Perceptron

DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Bu makale kapsamında Çoklu Lineer Regresyon, Polinomiyal Regresyon, Naive Bayes ve ÇKA' lar kalp hastalığı teşhisinde kullanılmış ve Doğruluk (*Accuracy*), Kesinlik (*Precision*), Duyarlılık (*Recall*) ve F-Ölçütü (*F-Score*) değerleri kıyaslanmıştır (Sokolova ve Lapalme, 2009). Doğruluk değeri tahmin edilmeye çalışılan durumun doğru tahmin edilme oranının yüzde olarak gösterimidir. Bir test verisinin Kalp

Hastası olması ve bunun eğitim sonucunda hasta yani pozitif olarak tahmin edilmesi Doğru Pozitif ($DP - TP$), hasta değil yani negatif olarak tahmin edilmesi Yanlış Negatif ($YN - FN$) olarak nitelendirilir. Aynı mantıkla gerçekte kalp hastası olmayan örnekler için kalp hastası değil olarak tahmin edilen sonuçlar Doğru Negatif ($DN - TN$), kalp hastası olarak tahmin edilen sonuçlar Yanlış Pozitif ($YP - FP$) olarak tanımlanmaktadır. Çizelge 2’de bu değerlerin tutulduğu Karmaşıklık Matrisi (Sokolova ve Lapalme, 2009) bulunmaktadır.

Çizelge 2. Karmaşıklık Matrisi

Table 2. Confusion Matrix

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	Doğru Pozitif	Yanlış Negatif
Gerçek Hayır	Yanlış Pozitif	Doğru Negatif

Üzerinde çalışılan veri kümesi örneğindeki veri dağılımına göre gerçek değerlerin dağılımları değişecektir. Örneğin kansızlık gibi daha sık görülen bir hastalıkta DP değerleri kanser hastalarını tutan bir veri kümesinde DP sayısından fazla olacaktır. Bu dağılımlar hesaplanan doğruluk değerine etki edecektir. Şöyle ki 9900 değer DP, 100 değer YP olduğu bir veri kümesinde test verileri çoğunluğun bulunduğu DP etiketi ile en basit algoritma ile etiketlense bile 0.99 gibi bir Doğruluk oranı bulunacaktır. Bu da sonuçların yanlış değerlendirilmesine sebep olacaktır. Bu sebeple literatürde Doğruluk değerinden ziyade Kesinlik ve Duyarlılık değerleri ve bu değerlerin harmonik ortalaması olan F-Ölçütü daha çok kullanılmaktadır.

Kesinlik; gerçekte pozitif olan ve pozitif olarak etiketlenen (DP) örnek sayısının model tarafından üretilen pozitif değerlerin sayısına oranıdır. Duyarlılık ise gerçekte pozitif olan ve doğru bir şekilde tahmin edilen (DP) örnek sayısının, tüm gerçek pozitif sayısına oranıdır. F₁-Ölçütü bu iki değer harmonik ortalamasıdır:

$$Kesinlik = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Pozitif} \quad (5)$$

$$Duyarlılık = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Negatif} \quad (6)$$

$$F_1\text{Ölçütü} = 2 * \beta * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (7)$$

F-Ölçütü değeri hesaplanırken $2*\beta$ sabit değişkendir. Literatürde (Zhao ve diğ., 2013) genellikle $\beta=1$ için hesaplanan F₁-Ölçütü değeri kullanılmaktadır. Yapılan çalışma kapsamında Çoklu Lineer Regresyon, Polinomiyal Regresyon, Naive Bayes, DVM, Rassal Orman ve ÇKA’lar kalp hastalığı teşhisinde kullanılmış ve Doğruluk, Kesinlik, Duyarlılık ve F₁ Ölçütü değerleri kıyaslanmıştır. Veri kümeleri bekletme yöntemi (20 çalıştırma) için rasgele bir şekilde %67’ye %33 oranla eğitim ve test olarak ikiye ayrılmış, modeller eğitim veri kümesiyle eğitildikten sonra test veri kümesiyle test edilmiştir. K katlama yöntemi için ise veri kümesi 10 parçaya bölünmüş ver her bir parça için ilgili parça test verisi diğer parçalar eğitim verisi olacak şekilde 10 adet farklı eğitim ve test verileri için modeller çalıştırılmıştır.

DeneySEL çalışmalar AMD Ryzen 7 3700U 2.3 GHz işlemcili 16 GB RAM kapasiteli ve 8 çekirdekli bilgisayar ortamında gerçekleştirilmiştir. Programlama dili olarak Python, yapay zeka kütüphanesi olarak scikit-learn kullanılmıştır. Deneyler Bekletme ve K katlama çapraz doğrulama yöntemleri ile çalıştırılarak en iyi sonuçlar ve ortalama sonuçlar çizelgelerde gösterilmiştir.

*Çoklu Lineer Regresyonun**En İyi Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Multi Layer Linear Regression*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	50	3
Gerçek Hayır	7	39

*İkinci Dereceden Polinomiyal Regresyonun**En İyi Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Second Degree Polynomial Regression*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	45	10
Gerçek Hayır	11	33

*Destek Vektör Makinesinin**En İyi Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Support Vector Machine*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	52	5
Gerçek Hayır	8	34

*Rassal Ormanın En İyi**Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Random Forest*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	46	3
Gerçek Hayır	10	40

*Gaussian Naive Bayes'in**En İyi Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Gaussian Naive Bayes*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	41	9
Gerçek Hayır	5	44

*Çok Katmanlı Algılayıcının**En İyi Sonucunun Karmaşıklık Matrisi**Confusion Matrix of Best Result of Multi Layer Perceptron*

	Tahmin Evet	Tahmin Hayır
Gerçek Evet	48	6
Gerçek Hayır	9	36

Şekil 5. Cleveland Veri Kümesi İçin En İyi Sonuçların Karşılaştırmalı Karmaşıklık Matrisleri (Bekletme Yöntemiyle)*Figure 5. Comparable Confusion Matrixes of Best Results for Cleveland Dataset (With Holdout)*

Yapılan deneyler sonucunda Cleveland veri kümesi için en yüksek başarımlı bekletme yöntemiyle Lineer Regresyonda elde edilmiştir. Doğru pozitif oranı %51, doğru negatif oranı %39, yanlış pozitif oranı %7, yanlış negatif oranı %3'tür.

Çoklu Lineer Regresyonda adım adım regresyon uygulanmış kalp hastalığı teşhisinde yaş ve kolesterol bilgisinin etkisiz olduğu saptanmış ve bu değişkenler Çoklu Lineer Regresyonda girdi kümesinden çıkarılmıştır. Çoklu Lineer Regresyonda 20 deney için çalıştırma süresi yaklaşık 33 salisedir.

Cleveland veri kümesi için bekletme yöntemi kullanılarak Polinomiyal Regresyon 2.,3. ve 4. derece için denenmiştir. 2. Dereceden Polinomiyal Regresyon için 0.79 Doğruluk, 0.82 Kesinlik, 0.78 Duyarlılık ve 0.77 F1 Ölçütü elde edilmiştir. 3. Dereceden Polinomiyal Regresyon için 0.72 Doğruluk, 0.70 Kesinlik, 0.82 Duyarlılık ve 0.68 F1 Ölçütü elde edilmiştir. 4. Dereceden Polinomiyal Regresyon için 0.71 Doğruluk, 0.74 Kesinlik, 0.71 Duyarlılık ve 0.70 F1 Ölçütü elde edilmiştir. Polinomiyal Regresyonda 20

deney için yaklaşık çalıştırma süresi 46 salisedir. Ayrıca Çoklu Lineer Regresyon ve Polinomiyal Regresyon için 0.5 üzerindeki çıktı değerleri 1, 0.5 altındaki çıktı değerleri 0 kabul edilmiştir.

Cleveland ve Z-Alizadehsani veri kümeleri için bekletme ve k katlama yöntemleri kullanılarak gerçekleştirilen Lineer Regresyon, Polynomial Regresyon, DVM, Rassal Orman, Naive Bayes ve ÇKA modelleri ile elde edilen en iyi sonuçlar Çizelge 3'te gösterilmiştir. Bu çizelgede ayrıca literatürde yapılmış diğer çalışmaların sonuçları da karşılaştırmalı olarak verilmiştir. Bu yöntemlerin ortalama sonuçları ise Çizelge 4'te görülmektedir. Çizelge 3'te testler sonucunda elde edilen en iyi sonuçlar sunulurken; Çizelge 4'te ortalama sonuçlar verilmiştir. Burada deneysel çalışmalar en iyi ve ortalama sonuçlar açısından analiz edilmiştir. Böylece çalışmada önerilen yaklaşımların farklı kriterlere göre değerlendirilmesi sağlanmıştır.

Rassal Orman yöntemi 20 ağaçlı ve ağaç derinliği 5 olarak tanımlanmıştır. Naive Bayes sınıflandırıcı için Multinomial Naive Bayes, Bernoulli Naive Bayes ve Gaussian Naive Bayes denenmiştir. Bu üç yöntem için yapılan karşılaştırmada en başarılı sonucu Gaussian Naive Bayes'in verdiği görülmüştür ki Çizelge 3'te gösterilen Naive Bayes sınıflandırıcı Gaussian sınıflandırıcının sonuçlarıdır. 20 deney için çalıştırma süresi yaklaşık 35 salisedir.

ÇKA kullanılarak gerçekleştirilen deneyler şu şekildedir: Öncelikle 128 nöronlu tek gizli katmanlı, maksimum iterasyon sayısı 5000, aktivasyon fonksiyonu olarak relu, öğrenme katsayısı 0.1, geri yayımda ağırlıkların optimizasyonu için stokastik gradyan inişi kullanılmıştır. Deneyler sonucunda en başarılı sonuç olarak 0.93, ortalama sonuç olarak 0.77 doğruluk değeri elde edilmiştir. Çalıştırma süresi 20 deney için yaklaşık 14 saniye sürmüştür.

Çizelge 3. Yapay Zeka Tekniklerinin Kalp Hastalığı Teşhisindeki Sonuçlarının Literatürle Karşılaştırılması

Table 3. Comparison of Results of Artificial Intelligence Techniques with Literature on Cardiac Disease Diagnosis

Referans	Model Adı	ZAlizadeh (Bekletme)			ZAlizadeh (K Katlama)			Cleveland (Bekletme)			Cleveland (K Katlama)		
		Doğru luk	Kesin lik	Duyarl ılık	Doğru luk	Kesin lik	Duyarl ılık	Doğru luk	Kesin lik	Duyarl ılık	Doğru luk	Kesin lik	Duyarl ılık
Bu Çalışma da Önerilen ve Kullanılan Yöntemler	Lineer Regresyon	0.91	0.90	0.93	0.93	1.0	1.0	0.90	0.98	0.85	0.93	1.0	1.0
	Polinomiyal Regresyon	0.82	0.71	0.76	0.87	0.75	0.90	0.79	0.82	0.78	0.87	0.92	0.94
	DVM	0.91	0.95	0.76	0.90	1.0	0.73	0.87	0.95	0.88	0.97	1.0	0.92
	Rassal Orman	0.92	0.95	0.74	0.93	1.0	0.80	0.87	0.93	0.85	0.87	1.0	0.92
	Naive Bayes	0.81	0.64	0.97	0.87	0.85	1.0	0.87	0.90	0.87	0.90	0.93	0.89
	ÇKA	0.86	0.92	0.85	0.90	0.87	1.0	0.85	0.88	0.88	0.90	0.94	0.91
Alizadeh sani ve diğ., 2013	ÇKA	-	-	-	0.88	-	0.91	-	-	-	-	-	-
	Naive Bayes	-	-	-	0.76	-	0.68	-	-	-	-	-	-
	SMO	-	-	-	0.94	-	0.96	-	-	-	-	-	-
Arabasadi ve diğ., 2017	Genetik + ÇKA	-	-	-	0.94	-	0.97	-	-	-	0.89	-	0.88
Yar ve diğ., 2020	Karar Ağacı	-	-	-	-	-	-	-	-	-	0.87	0.85	0.90
	Lojistik Regresyon	-	-	-	-	-	-	-	-	-	0.84	0.81	0.90
	ÇKA	-	-	-	-	-	-	-	-	-	0.85	0.83	0.84
	DVM	-	-	-	-	-	-	-	-	-	0.84	0.80	0.93
	Rassal Orman	-	-	-	-	-	-	-	-	-	0.89	0.91	0.89
	Naive Bayes	-	-	-	-	-	-	-	-	-	0.82	0.81	0.86
Referans	Model Adı	ZAlizadeh (Bekletme)			ZAlizadeh (K Katlama)			Cleveland (Bekletme)			Cleveland (K Katlama)		
		Doğru luk	Kesin lik	Duyarl ılık	Doğru luk			Doğru luk	Kesin lik	Duyarl ılık	Doğru luk		
Gupta ve diğ., 2021	DHMZ	0.95	-	0.98	-	-	-	-	-	-	-	-	-
Ayon ve diğ., 2020	Ken yakın komşu	-	-	-	-	-	-	-	-	-	0.94	0.96	0.93
	DVM	-	-	-	-	-	-	-	-	-	0.97	0.97	0.95
	Naive Bayes	-	-	-	-	-	-	-	-	-	0.91	0.93	0.91
	ÇKA	-	-	-	-	-	-	-	-	-	0.97	0.97	0.98
	Rassal Orman	-	-	-	-	-	-	-	-	-	0.89	0.89	0.90
Mienye ve diğ., 2020	Lojistik Regresyon	-	-	-	-	-	-	0.78	0.79	0.78	-	-	-
	DVM	-	-	-	-	-	-	0.79	0.80	0.79	-	-	-
	Naive Bayes	-	-	-	-	-	-	0.81	0.79	0.84	-	-	-
	Rassal Orman	-	-	-	-	-	-	0.83	0.81	0.87	-	-	-
	SRA	-	-	-	-	-	-	0.93	0.96	0.91	-	-	-

Çizelge 3. Yapay Zeka Tekniklerinin Kalp Hastalığı Teşhisindeki Ortalama Sonuçlarının Karşılaştırılması

Table 4. Comparison of Average Results of Artificial Intelligence Techniques on Cardiac Disease Diagnosis

Ölçütler/ Yöntemler	Çoklu Lineer Regresyon	İkinci Dereceden Polinomial Regresyon	Destek Vektör Makinesi	Rassal Orman	Gaussian Naive Bayes Sınıflandırıcı	Çok Katmanlı Algılayıcı
Doğruluk (Cleveland Bekletme)	0.84	0.71	0.81	0.81	0.81	0.79
Doğruluk (ZAlizadeh Bekletme)	0.85	0.76	0.85	0.84	0.74	0.82
Doğruluk (Cleveland K Katlama)	0.83	0.76	0.81	0.83	0.83	0.76
Doğruluk (ZAlizadeh K Katlama)	0.87	0.73	0.85	0.86	0.74	0.84
Kesinlik (Cleveland Bekletme)	0.86	0.69	0.80	0.83	0.81	0.78
Kesinlik (ZAlizadeh Bekletme)	0.72	0.60	0.83	0.80	0.54	0.70
Kesinlik (Cleveland K Katlama)	0.84	0.76	0.82	0.83	0.84	0.75
Kesinlik (ZAlizadeh K Katlama)	0.77	0.54	0.85	0.78	0.53	0.71
Duyarlılık (Cleveland Bekletme)	0.78	0.66	0.79	0.75	0.79	0.76
Duyarlılık (ZAlizadeh Bekletme)	0.78	0.60	0.60	0.62	0.85	0.70
Duyarlılık (Cleveland K Katlama)	0.55	0.75	0.76	0.80	0.78	0.75
Duyarlılık (ZAlizadeh K Katlama)	0.82	0.56	0.62	0.69	0.88	0.77
F ₁ Ölçütü (Cleveland Bekletme)	0.82	0.67	0.79	0.79	0.80	0.76
F ₁ Ölçütü (ZAlizadeh Bekletme)	0.74	0.60	0.69	0.70	0.65	0.70
F ₁ Ölçütü (Cleveland K Katlama)	0.81	0.74	0.78	0.80	0.80	0.75
F ₁ Ölçütü (ZAlizadeh K Katlama)	0.78	0.53	0.71	0.72	0.65	0.73

SONUÇLAR VE ÖNERİLER (RESULTS and SUGGESTIONS)

Kalp hastalıkları günümüzde ölüm sebeplerinin başlıcalarındandır. Bu hastalıktan kaynaklı ölümlerin önüne geçebilmek için erken dönemde teşhis ve tedavi oldukça önemlidir. Bu çalışmada kalp hastalığı teşhisinde kullanılacak yapay zeka tabanlı bir karar destek mekanizması önerilmiştir. Kullanılan yapay zeka yöntemleri çoklu lineer regresyon, polinomial regresyon, destek vektör makinesi, rassal orman, naive bayes sınıflandırıcılardan ve çok katmanlı algılayıcıdan oluşmaktadır. Yapılan çalışmalar bu alanda sıklıkla kullanılan Cleveland ve Z-Alizadehsani veri kümeleri üzerinde gerçekleştirilmiştir. Her bir yöntem için bekletme çapraz doğrulama yöntemleriyle 20 farklı deney gerçekleştirilmiştir. Bununla birlikte K katlama için 10 farklı eğitim ve test kümesi oluşturulmuş ve her biri için modeller çalıştırılmıştır. Bekletme yöntemi gerçeğe en yakın ortalama sonucu verdiği için

aslında gerçek model doğruluğunun 10 K katlama yöntemi ile tam olarak bulunamadığı görülmüştür. Z-Alizadehsani veri kümesi için en yüksek doğruluk 0.93 olarak K katlama ile Rassal Orman modeli kullanılarak elde edilmiştir. Cleveland veri kümesi için ise en yüksek doğruluk 0.97 olarak K katlama ile DVM kullanılarak elde edilmiştir.

Çizelge 3 ve Çizelge 4 incelendiğinde iki veri kümesi için de yapılan deneylerin sonuçlarının birbirleriyle tutarlı olduğu görülmektedir. Örnek sayısı aynı olan iki farklı veri kümesi için kullanılan yöntemlerin benzer sonuçlar verdiği gözlemlenmiştir.

Sonuç olarak, kalp hastalığı teşhisinde hastanelerde ve klinik merkezlerde uygulanan ölçümlere entegre edilecek bir yapay zeka temelli karar destek sistemi erken ve doğru teşhiste önemli rol oynayabilecektir. Bu entegrasyon sağlık çalışanlarının hastanın sağlık verilerini girebileceği bir masaüstü veya web tabanlı uygulama ile yapılabileceği gibi tüm hastanelerin ve klinik merkezlerin bağlantı aracılığıyla ulaşabileceği yapay zeka tabanlı bir web servis olarak da kullanıma sunulabilir. Web servis olarak kullanıma sunulması durumunda yapay zekanın yeni verilerle sürekli olarak öğrenmeye devam etmesi sağlanabilir. Böylece sistem kendini zaman içerisinde dinamik olarak geliştirecektir. Böyle bir sistemde dinamik öğrenme yaklaşımları ve hibrit sistemler uygulanabilecektir. Ayrıca ele alınan teknikler farklı ölçüm verileriyle şeker hastalığı, böbrek hastalıkları vb. hastalıkların erken ve doğru teşhisi için kullanılabilir.

KAYNAKÇA (REFERENCES)

- Alizadehsani, R., Habibi, J., Hosseini, M. J., Mashayekhi, H., Boghrati, R., Ghandeharioun, A., Bahadorian, B., Sani, Z. A., 2013, "A data mining approach for diagnosis of coronary artery disease", *Computer Methods and Programs in Biomedicine*, Cilt 111, Sayı 1, ss. 52-61.
- Alizadehsani, Z., Alizadehsani, R., Roshanzamir, M., , 2017, Z-Alizadeh Sani Data Set, <https://archive.ics.uci.edu/ml/datasets/Z-Alizadeh+Sani>, ziyaret tarihi: 24 Ekim 2021
- Alkhodari, M., Fraiwan, L., 2021, "Convolutional and recurrent neural networks for the detection of valvular heard diseases in phonocardiogram recordings", *Computer Methods and Programs in Biomedicine*, Cilt 200.
- Akalın, B., Veranyurt, Ü., Veranyurt, O., 2020, "Classification of individuals at risk of heart disease using machine learning", *Cumhuriyet Medical Journal*, Cilt 42, Sayı 3, ss. 283-289.
- Arabasadi, Z., Alizadehsani, R., Roshanzamir, M., Moosaei, H., Yarifard, A. A., 2017, "Computer aided decision making for heart disease detection using hybrid neural network-Genetic algorithm", *Computer Methods and Programs in Biomedicine*, Cilt 141, ss. 19-26.
- Ayon, S. I., Islam, M. M., Hossain, M. R., 2020, "Coronary artery heart disease prediction: a comparative study of computational intelligence techniques", *IETE Journal of Research*, ss. 1-20.
- Chen, A. H., Huang, S. Y., Hong, P. S., Cheng, C. H., Lin, E. J., 2011, "HDPS: Heart disease prediction system", *2011 computing in cardiology, IEEE*, ss. 557-560.
- Cristianini, N., Shawe-Taylor, J., 2000, *An introduction to support vector machines and other kernel-based learning methods*, Cambridge university press.
- Dutta, A., Batabyal, T., Basu, M., Acton, S. T., 2020, "An efficient convolutional neural network for coronary heart disease prediction", *Expert Systems with Applications*, Cilt 159.
- Ekrem, Ö., Musleh Salman, O. K., Aksoy, B., İnan, S. A., 2020, "Yapay Zeka Yöntemleri Kullanılarak Kalp Hastalığının Tespiti", *Journal of Engineering Sciences and Design*, Cilt 8, Sayı 5, ss. 241-254.
- Fadlil, A., Riadi, I., Aji, S., 2017, "Ddos attacks classification using numeric attribute-based gaussian naive bayes", *International Journal of Advanced Computer Science and Applications (IJACSA)*, Cilt 8, sayı 8, ss. 42-50.
- Friedman, N., Geiger, D., Goldszmidt, M., 1997, "Bayesian network classifiers", *Machine learning*, Cilt 29, Sayı 2, ss. 131-163.
- Ghahramani, Z., 2003, "Unsupervised learning", *Summer School on Machine Learning*, Berlin, Springer, ss. 72-112.

- Gupta, A., Arora, H. S., Kumar, R., Raman, B., 2021, "DMHZ: A Decision Support System Based on Machine Computational Design for Heart Disease Diagnosis Using Z-Alizadeh Sani Dataset", *IEEE International Conference on Information Networking (ICOIN)*, ss. 818-823.
- Hornik, K., Stinchcombe, M., White, H., 1989, "Multilayer feedforward networks are universal approximators", *Neural Networks*, Cilt 2, ss. 359-366.
- Hsieh, N. C., Hung, L. P., Shih, C. C., Keh, H. C., Chan, C. H., 2012, "Intelligent Postoperative Morbidity Prediction of Heart Disease Using Artificial Intelligence Techniques", *Journal of Medical Systems*, Cilt 36, Sayı 3, ss. 1809-1820.
- Jain, A. K., Mao J., Mohiuddin, K. M., 1996, "Artificial neural networks: A tutorial", *Computer*, Cilt 29, Sayı 3, ss. 31-44.
- Janosi, A., Steinbrunn, W., Pfisterer, M., Detrano, R., 1988, Heart Disease Data Set, <https://archive.ics.uci.edu/ml/datasets/heart+disease>, ziyaret tarihi: 7 Ağustos 2021.
- Kibriya, A. M., Frank, E., Pfahringer, B., Holmes, G., 2004, "Multinomial naive bayes for text categorization revisited", *Australasian Joint Conference on Artificial Intelligence*, Berlin.
- Kolukisa, B., Hacilar, H., Kuş, M., Bakır-Güngör, B., Aral, A., Güngör, V. Ç., 2019, "Diagnosis of coronary heart disease via classification algorithms and a new feature selection methodology", *International Journal of Data Mining Science*, Cilt 1, Sayı 1, ss. 8-15.
- Kotsiantis, S. B., Zaharakis, I., Pintelas, P., 2007, "Supervised machine learning: A review of classification techniques", *Emerging artificial intelligence applications in computer engineering*, IOS Press, ss. 3-24.
- Masih, N., Naz, H., Ahuja, S., 2021, "Multilayer perceptron based deep neural network for early detection of coronary heart disease", *Health And Technology*, Cilt 11, ss. 127-138.
- Mienye, I. D., Sun, Y., Wang, Z., 2020, "An improved ensemble learning approach for the prediction of heart disease risk", *Informatics in Medicine Unlocked*, Cilt 20.
- Mohan, S., Thirumalai, C., Srivastava, G., 2019, "Effective heart disease prediction using hybrid machine learning techniques", *IEEE Access*, Cilt 7, ss. 81542-81554.
- Oshiro, T. M., Perez, P. S., Baranauskas, J. A., 2012, "How many trees in a random forest?", *International workshop on machine learning and data mining in pattern recognition*, Berlin.
- Ostertagova, E., 2012, "Modelling using polynomial regression", *Procedia Engineering*, ss. 500-506.
- Qi, Z., Zuoru, Z., 2021, "A hybrid cost-sensitive ensemble for heart disease prediction", *BMC Medical Informatics and Decision Making*, Cilt 21, Sayı 1, ss. 1-18.
- Raschka, S., 2014, "Naive bayes and text classification i-introduction and theory", *arXiv preprint*.
- Rosenblatt, F., 1958, "The perceptron: A probabilistic model for information storage and organization in the brain", *Psychoanalytic*, ss. 386-408.
- Safavian, S. R., Landgrebe, D., 1991, "A survey of decision tree classifier methodology", *IEEE transactions on systems, man, and cybernetics*, Cilt 21, Sayı 3, ss. 660-674.
- Seber, G. A. F., Lee, A. J., 2012, *Linear Regression Analysis*, John Wiley & Sons.
- Shorewala, V., 2021, "Early detection of coronary heart disease using ensemble techniques", *Informatics in Medicine Unlocked*, pp. Pre-proof.
- Smets, P., 1993, "Belief functions: the disjunctive rule of combination and the generalized Bayesian theorem", *International Journal of approximate reasoning*, Cilt 9, Sayı 1, ss. 1-35.
- Sokolova, M., Lapalme, G., 2009, "A systematic analysis of performance measures for classification tasks", *Information Processing and Management*, Cilt 45, ss. 427-437.
- Tabachnick, B. G., Fidell, L. S., Ullman, J. B., 2007, *Using multivariate statistics*, Boston: MA: Pearson.
- TÜİK, Ölüm ve Ölüm Nedeni İstatistikleri, 2019, <https://data.tuik.gov.tr/Bulten/Index?p=Olum-ve-Olum-Nedeni-Istatistikleri-2019-33710>, ziyaret tarihi: 07 Ağustos 2021.
- Yar, M., Muhammad, T. , Maqsood H., Kil To, C., 2020, "Early and accurate detection and diagnosis of heart disease using intelligent computational model", *Scientific Reports*, Cilt 10, Sayı 1.

Zhao, M. J., Edakunni, N., Pocock, A., & Brown, G, 2013, "Beyond Fano's inequality: Bounds on the optimal F-score, BER, and cost-sensitive risk and their implications", *The Journal of Machine Learning Research*, Cilt 14, Sayı 1, ss. 1033-1090.