

# Makine öğrenmesi algoritmaları ile kalp hastalığı tespitinin performans karşılaştırmaları

## Performance comparison of heart disease detection with machine learning algorithms

Bekir Can TELKENAROĞLU<sup>1</sup>, Bahar DEMİRTÜRK<sup>2\*</sup>, Bayram KÖSE<sup>3</sup>

<sup>1</sup>Akıllı Sistemler Mühendisliği Bölümü, İzmir Bakırçay Üniversitesi, İzmir, Türkiye.  
6016039@bakircay.edu.tr

<sup>2</sup>Temel Bilimler Bölümü, Mühendislik ve Mimarlık Fakültesi, İzmir Bakırçay Üniversitesi, İzmir, Türkiye.  
bahar.demirturk@bakircay.edu.tr

<sup>3</sup>Elektrik Elektronik Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi, İzmir Bakırçay Üniversitesi, İzmir, Türkiye.  
bayram.kose@bakircay.edu.tr

Geliş Tarihi/Received: 24.01.2024  
Kabul Tarihi/Accepted: 27.01.2025

Düzeltilme Tarihi/Revision: 13.01.2025

doi: 10.5505/pajes.2025.34539  
Araştırma Makalesi/Research Article

### Öz

Kalp hastalıkları, dünya çapında önde gelen ölüm nedenlerinden biri olup, erken teşhis ve doğru tedavi planlaması hastaların yaşam kalitesi ve hayatta kalma oranları açısından kritik öneme sahiptir. Bu çalışma ile makine öğrenmesi algoritmalarının kalp hastalığı teşhisindeki performansının Weka platformunda kapsamlı biçimde incelenmesi amaçlanmaktadır. Veri madenciliği yöntemleri kullanılarak elde edilen veri seti üzerinde; regresyon, sınıflandırma ve kümeleme algoritmaları uygulanmış, ardından kesinlik, hassasiyet ve F-skoru gibi performans ölçütleriyle değerlendirilmiştir. Bulgular, incelenen çeşitli algoritmaların kalp hastalığı teşhisinde başarı sağladığını ortaya koymaktadır. Elde edilen sonuçlar, hem sağlık profesyonelleri hem de araştırmacılar için makine öğrenmesi tekniklerinin kalp hastalığı teşhisine uygulanması konusunda yol gösterici niteliktedir ve hasta teşhis süreçlerinin iyileştirilmesine katkı sunmaktadır.

**Anahtar kelimeler:** Weka, Makine Öğrenmesi Algoritmaları, Performans Analizi, Veri Analizi.

### Abstract

Heart diseases are one of the leading causes of death worldwide, and early diagnosis and proper treatment planning are critical for patients' quality of life and survival rates. This study aims to comprehensively investigate the performance of machine learning algorithms in heart disease diagnosis on the Weka platform. Regression, classification and clustering algorithms were applied on the data set obtained using data mining methods, and then evaluated with performance measures such as precision, accuracy and F-score. The findings reveal that the various algorithms examined provide success in the diagnosis of heart disease. The obtained results provide guidance for both healthcare professionals and researchers on the application of machine learning techniques to heart disease diagnosis and contribute to the improvement of patient diagnosis processes.

**Keywords:** Weka Machine Learning Algorithms, Performance Analysis, Data Analysis.

## 1 Giriş

Kalp hastalıkları, dünya genelinde sağlık sorunları arasında önde gelen ölüm nedenlerinden biridir. Erken teşhisin, hastaların tedaviye başlama sürecini hızlandırarak, yaşam kalitesini artırabileceği göz önüne alındığında, kalp hastalığının teşhisi için etkili yöntemlerin geliştirilmesi de oldukça önemlidir. Doktorların mesleki tecrübesine ve sınırlı tanı testlerine bağlı olarak çeşitlenen geleneksel tanı yöntemleri ile hastalıkların erken dönemde fark edilip önlem alınması kimi zaman zor olmaktadır. Ancak son yıllarda makine öğrenmesi alanında yapılan çalışmalar sayesinde sağlık alanında da daha sistematik ve verilere dayalı bir yaklaşımın getirilmesi sağlanmaktadır. Böylece teşhis süreçlerinde önemli iyileştirmeler ortaya çıkmaktadır. Çeşitli hasta verilerinden elde edilen kapsamlı bilgiler ile makine öğrenmesi algoritmaları kullanılarak karar destek sistemlerinin oluşturulması sağlanmaktadır. Ayrıca sınıflandırma ve kümeleme yöntemleri ile hastalıkların çeşitli risk grupları belirlenerek, uygun sağlık stratejilerinin önerilmesine katkı sağlanmaktadır.

Kalp en hayati organların başında gelir. Kalpte ve kan damarlarında meydana gelen sorunlar, koroner kalp hastalığı, kalp yetmezliği, beyin damar hastalıkları, romatizmal kalp hastalığı, hipertansiyon, aritmiler gibi başka birçok hastalığa neden olur. Ancak bazı kişiler, bu risk faktörlerinin farkında olmadığından erken müdahale şansını kayırabilmektedir. Bu kişiler, hastanelerde geç veya eksik tedavi alarak hastalığın ilerlemesine ya da erken ölümlere maruz kalabilmektedir [1]. Erken teşhis, bu hastalıkların etkilerini hafifletmek ve hastaların yaşam süresini uzatmak açısından kritik öneme sahiptir [2].

Makine öğrenmesi yöntemleri, sağlık sektöründe veri analizi ve hastalıkların teşhisi ve karmaşık problemlerin çözümü için oldukça yaygın kullanılan bir araç haline gelmiştir. Bu teknikler, büyük veri setlerini analiz etme ve problemleri çözmeye etkindir [3,4,5]. Weka, ücretsiz ve açık kaynaklı bir veri madenciliği yazılım aracı olup içeriğinde pek çok makine öğrenmesi algoritması bulundurmaktadır [6,7]. Bu tür veri madenciliği araçları, araştırmacılara ve sağlık profesyonellerine veri analizi ve makine öğrenmesi algoritmalarını uygulamak için kullanışlı bir platform sunar [8].

\*Yazışılan yazar/Corresponding author

Kalp Hastalıklarının çeşitli makine öğrenme algoritmaları ile tahmin edilmesi birçok yazarın ilgisini çekmiş ve literatüre çok sayıda yayınlara katkıda bulunmuşlardır. Bunlardan bazıları şu şekilde sıralanabilir.

Çoşar ve Deniz, Lojistik Regresyon, kNN ve Rasgele Orman algoritmalarını kullanarak örnek bir model oluşturulmuş ve kalp rahatsızlığı olan bireyleri tespit etmeye çalışmışlardır [9]. Mohan ve ark. [10], Destek Vektör Makineleri, Rastgele Orman, Örnek Öğrenme gibi makine öğrenmesi algoritmalarını kullanarak, F-skoru, hassasiyet ve özgüllük gibi metriklerle kalp hastalığını tespit etmede en yüksek doğruluk oranına ulaşmaya çalışmışlardır. Elde ettikleri tutarlı sonuçlar ile önerdikleri yaklaşımları ağırlıklı olarak kuramsal modeller ve simülasyonlar kapsamında değerlendirmektedirler.

Dipto ve ark. [11], koroner arter hastalığının tahmini için Destek Vektör Makinesi (SVM), Yapay Sinir Ağları ve Lojistik Regresyon algoritmalarını sentetik veri üreterek kullanmışlardır. Çalışmalarında, Destek Vektör Makinesi modelinin en yüksek doğruluğa sahip olduğunu ve sentetik veri kullanarak sonuçlarda iyileşme yapılabileceğini belirtmişlerdir. Bulgular, SVM'nin performansının daha iyi olduğunu ve belirli bir test oranıyla genellenebileceğini göstermektedir. Lojistik regresyon ise büyük veri üzerinde en iyi performansı vermiştir.

Kim ve Kang [12], KNHANES V veri setinden elde edilen verileri kullanarak Yapay Sinir Ağları tabanlı koroner kalp hastalığı tahmini üzerinde çalışmıştır. Analizde C4.5 Karar Ağacı ve K-En Yakın Komşu (KNN) yöntemi %82.5 doğruluk sağlamıştır. Mohamed ve Ali [13], sınıflandırma algoritmalarını Weka platformu üzerinde kullanarak kalp hastalığı tahmini için öneriler sunmuşlardır. Sen [14], çalışmasında Bayes ağı, destek vektör makineleri, C4.5 karar ağacı ve k-en yakın komşu algoritmalarının performanslarını kalp hastalığı teşhisi için karşılaştırmışlardır.

Bu çalışmada ise üç farklı kategori altında ele alınan makine öğrenmesi algoritmalarının Weka platformunda, kalp hastalıklarını teşhis etme yeteneği incelenerek, performansları karşılaştırılacak ve böylelikle sağlık profesyonellerine yeni çözümler sunma imkanı ortaya çıkacaktır.

## 2 Veri Seti ve Metodoloji

Kardiyovasküler hastalıklar dünya çapında ölüm oranlarını önemli ölçüde artıran sağlık sorunlarının başında gelmektedir. Yılda yaklaşık 17.9 milyon ölümün nedeni olarak kabul edilir ve dünya genelinde ölümlerin yaklaşık %31'ine tekabül eder. Bu ölümlerin büyük bir kısmı, kalp krizi ve felç gibi kardiyovasküler olaylardan kaynaklanmaktadır. Bu tür ölümlerin üçte biri ise 70 yaşın altındaki bireylerde görülmektedir [2]. Kalp yetmezliği, kardiyovasküler hastalıkların yaygın bir sonucu olarak öne çıkar ve bu nedenle erken teşhis ve müdahale gerekmektedir.

Bu çalışmada, KAGGLE üzerinden açık erişimle sunulan "Heart Failure Prediction Dataset" veri seti ele alınmıştır. Bu veri seti, farklı kaynaklardan elde edilen ve daha önce birleştirilmemiş beş farklı kalp veri setinin birleştirilmesiyle oluşturulmuştur. Bu birleştirme sonucunda toplamda 1190 farklı gözlem elde edilmiş ve bu gözlemler incelendikten sonra 272'si veri setinden eleme yoluyla çıkartılarak toplamda 918 veriyi içeren büyük bir veri seti elde edilmiştir [15]. Bu veri seti, 11 farklı öznelikli içerir. Bu özellikler; yaş, cinsiyet, göğüs ağrısı tipi, dinlenme kan basıncı, kolesterol seviyesi, açlık kan şekeri, istirahat elektrokardiyogram sonuçları, maksimum kalp atış hızı, egzersize bağlı anjina, ST segment depresyonu ve ST

eğiminin yönüdür. Tablo 1'de veri setinde yer alan öznelikler, tanımlamalar ve özneliklerin nümerik-nominal değerleri verilmiştir.

Tablo 1. Veri seti özellikleri.

Table 1. Data set characteristics.

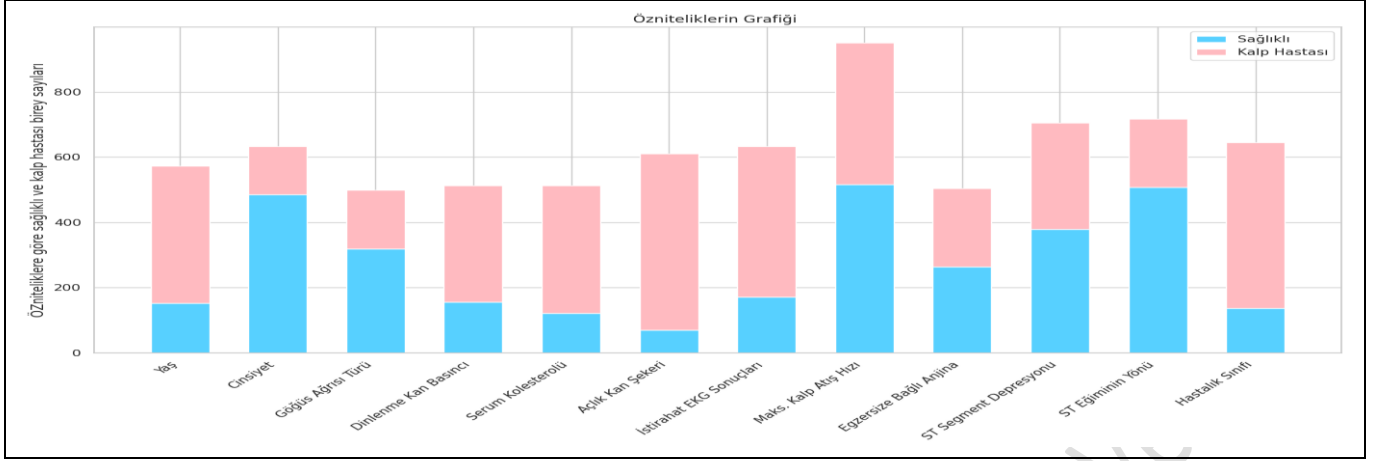
Öznitelik	Tanımlama	Nümerik-Nominal
Age	Yaş	25 ≤ genç ≤ 49 50 ≤ orta yaş ≤ 64 65 ≤ yaşlı
Sex	Cinsiyet	1=erkek, 0=kadın
Chest Pain Type	Göğüs Ağrısı Türü	TA-1, ATA-2, NAP-3, ASY-4
Resting BP	Dinlenme Kan Basıncı	0 ≤ düşük ≤ 109 110 ≤ normal ≤ 130 131 ≤ yüksek
Cholesterol	Serum Kolesterolü	0 ≤ normal ≤ 230 231 ≤ yüksek
Fasting BS	Açlık Kan Şekeri	0 ≤ normal ≤ 120 121 ≤ yüksek
Resting ECG	İstirahat EKG Sonuçları	Normal-1, ST-2, LVH-3
MaxHR	Maks. Kalp Atış Hızı	0 ≤ düşük ≤ 70 71 ≤ normal ≤ 120 121 ≤ yüksek
Exercise Angina	Egzersize Bağlı Anjina	Y = 1 N = 0
Oldpeak	ST Segment Depresyonu	-5 ≤ düşük ≤ 1.5 1.5 ≤ normal ≤ 3 3.1 ≤ yüksek
ST_Slope	ST Eğiminin Yönü	Up(yukarı)-1 Flat(yatay)-2 Down(aşağı)-3
Heart Disease	Hastalık Sınıfı	1 = kalp hastası 0 = sağlıklı

Şekil 1, veri setinde yer alan çeşitli özneliklere dayalı olarak sağlıklı ve kalp hastası bireylerin sınıflandırılmasını göstermektedir. Mavi renk sağlıklı bireyleri, pembe renk ise kalp hastası bireyleri temsil etmektedir.

Şekil 1 incelendiğinde, genç bireylerde sağlıklı birey oranının kalp hastası bireylere göre daha yüksek olduğu görülmektedir. Bununla birlikte, orta yaşlı ve yaşlı bireylerde kalp hastalığına sahip olanların oranının sağlıklı bireylere göre daha yüksek olduğu dikkat çekmektedir.

Cinsiyet bazında, erkek bireylerde kalp hastası bireylerin oranının sağlıklı bireylere göre daha yüksek olduğu gözlemlenirken, kadın bireylerde sağlıklı bireylerin oranının kalp hastalığına sahip bireylere göre daha yüksek olduğu belirlenmektedir. Bu cinsiyet bazlı farklılıklar, kalp hastalığının cinsiyetle ilişkilendirilmiş olabileceğine dair önemli bir gözlemi ortaya koymaktadır. Ayrıca göğüs ağrısı türlerine göre incelendiğinde, TA ve ATA göğüs ağrısı türüne sahip bireylerde sağlıklı birey oranının kalp hastası bireylere göre daha yüksek olduğu görülmektedir. NAP göğüs ağrısı türüne sahip bireylerde ise kalp hastası olanların oranının sağlıklı bireylere göre daha yüksek olduğu saptanmıştır.

Dinlenme kan basıncı ve kolesterol düzeyi açısından incelendiğinde, düşük dinlenme kan basıncına sahip bireylerde kalp hastası olanların oranının sağlıklı bireylere göre daha yüksek olduğu görülmekte, ancak normal dinlenme kan basıncına sahip bireylerde durumun tersine olduğu gözlemlenmektedir.



Şekil 1. Tüm özniteliklerin görselleştirilmesi.

Figure 1. Visualization of all attributes.

Benzer şekilde, kolesterolü normal olan bireylerde sağlıklı birey oranının kalp hastası bireylere göre daha yüksek olduğu, yüksek kolesterol düzeyine sahip bireylerde ise kalp hastası olanların oranının daha yüksek olduğu tespit edilmektedir. Açlık kan şekeri normal olan bireylerde sağlıklı bireylerin oranının kalp hastası bireylere göre daha yüksek olduğu görülmekte ancak açlık kan şekeri yüksek olan bireylerde durumun tersine olduğu gözlenmektedir. İstirahat EKG sonuçları normal, ST ve LVH olan bireylerde sağlıklı birey oranının kalp hastası bireylere göre daha yüksek olduğu görülmektedir.

Maksimum kalp atış hızı düşük olan bireylerde sağlıklı bireylerin oranının kalp hastası bireylere göre yüksek olduğu, maksimum kalp atış hızı normal ve yüksek olan bireylerde ise kalp hastası bireylerin oranının sağlıklı bireylere göre yüksek olduğu tespit edilmiştir. Egzersize bağlı anjinası olmayan bireylerde sağlıklı bireylerin oranının kalp hastası bireylere göre yüksek olduğu, egzersize bağlı anjinası olan bireylerde ise kalp hastası bireylerin oranının sağlıklı bireylere göre yüksek olduğu saptanmıştır. ST segment depresyon değeri düşük olan bireylerde sağlıklı bireylerin oranının kalp hastası bireylere göre yüksek olduğu, ST segment depresyon değeri normal ve yüksek olan bireylerde ise kalp hastası bireylerin oranının sağlıklı bireylere göre yüksek olduğu belirlenmiştir. ST eğiminin yönü yukarı olan bireylerde sağlıklı birey oranının kalp hastası bireylere göre yüksek olduğu görülmektedir. Ancak, ST eğiminin yönü yatay ve aşağı yönlü olan bireylerde kalp hastası bireylerin oranının sağlıklı bireylere göre daha yüksek olduğu tespit edilmiştir.

Genel olarak, Şekil 1'de yer alan bu analiz, farklı yaş grupları, cinsiyet, göğüs ağrısı tipleri, dinlenme kan basıncı, kolesterol düzeyleri, açlık kan şekeri, istirahat EKG sonuçları, maksimum kalp atış hızı, egzersize bağlı anjina, depresyon değerleri ve ST eğimi gibi özniteliklerin kalp hastalığı ile nasıl ilişkilendirilebileceği konusunda değerli bir katkı sunmaktadır.

Bu çalışmanın temel amacı, ele alınan bu geniş veri seti üzerine Weka platformunda uygulanan makine öğrenmesi algoritmalarıyla kalp hastalığı riskini tahmin etmektir. Bu veri setinin kullanımı, kardiyovasküler hastalığı olan veya yüksek risk taşıyan bireylerin erken teşhis edilmesi için önemlidir. Bu hastalar genellikle hipertansiyon, diyabet, hiperlipidemi veya önceden belirlenmiş hastalık gibi risk faktörlerine sahiptirler. Bu nedenle, veri madenciliği ve yapay zeka tekniklerinin

kullanılması, bu hastalıkları erken teşhis etmek ve uygun tedaviye başlamak için önemli bir araçtır.

## 2.1 Weka Platformu ve Makine Öğrenmesi Algoritmaları

Bu çalışmada kalp hastalığı teşhisinde Weka yazılımının sunduğu makine öğrenmesi algoritmaları kullanarak etkili bir analiz gerçekleştirilmiştir. Weka, Waikato Üniversitesi'nde geliştirilen ve "Waikato Environment for Knowledge Analysis" kelimesinin baş harflerinden oluşan bir yazılımdır. Günümüzde yaygın olarak kullanılan bir dizi makine öğrenmesi algoritmasını içerir ve kendi içerisinde arff uzantısı desteğiyle birlikte gelir [16].

Kalp hastalığı teşhisinde, makine öğrenmesi algoritmalarından, regresyon, sınıflandırma ve kümeleme algoritmaları kullanılarak bu algoritmaların ayrıntılı şekilde değerlendirilmesi bu bölümde yapılmıştır. Bu algoritmalar arasında lineer regresyon, M5P, LibSVM, IBK, BM ve X-Means yer almaktadır. Her bir algoritmanın başarı oranları, bireylerin kalp hastası olup olmadığını tahmin etme yeteneklerini değerlendirmek için kullanılmıştır. Veri setinde bulunan öznitelikler, kullanılan algoritma türüne göre nümerik veya nominal olarak düzenlenmiştir. Bu düzenleme, algoritmaların doğru bir şekilde çalışabilmesi için önemlidir. Özellikle, regresyon ve sınıflandırma algoritmaları için özniteliklerin doğru türde düzenlenmesi, analizin doğruluğunu etkileyen kritik bir faktördür [9,15].

Veri setindeki bireylerin kalp hastası ya da sağlıklı olduğunun tahmininde kullanılan algoritmaların başarı oranları, analizin güvenilirliğini değerlendirmek amacıyla karşılaştırılmıştır. Bu karşılaştırma, Weka yazılımının sağladığı geniş algoritma yelpazesi içinde en etkili yöntemin belirlenmesini hedeflemektedir. Algoritmaların seçimi ve performans değerlendirilmesi gibi adımlar bu çalışmada kalp hastalığı riskini değerlendirmek ve hastalığın erken teşhisi için güçlü bir analitik temel oluşturmak açısından oldukça önemlidir.

Bölüm 2.1.1, Bölüm 2.1.2 ve Bölüm 2.1.3'te, veri setine uygulanacak regresyon, sınıflandırma ve kümeleme algoritmalarından bahsedilecektir. Bu alt bölümlerde verilecek tablolarda geçen performans ölçütlerinin açıklamaları Bölüm 4'te detaylı olarak ele alınacaktır.

### 2.1.1 Regresyon Algoritmaları

Regresyon, bağımlı değişkenlerle bağımsız değişkenler arasındaki ilişkiyi analiz etmek ve bu ilişkiyi kullanarak bağımlı değişkenin tahminini yapmak için kullanılan bir makine öğrenmesi yaklaşımıdır. Bu kısımda, ele alınan veri setindeki çeşitli öznitelikler ile kalp hastalığı riskini tahmin etmek için kullandığımız regresyon algoritmalarının temel prensipleri açıklanmıştır. Bu algoritmalarından lineer regresyon, basit ve anlaşılır bir modelleme sağlarken, M5P algoritması veri setindeki daha karmaşık ilişkileri ele alır. Regresyon algoritmaları çalışmanın temel analitik araçlarıdır ve her birinin performansı, kalp hastalığı riski tahminindeki etkinlikleri açısından değerlendirilmiştir [17].

#### 2.1.1.1 Lineer Regresyon Algoritması

Lineer regresyon, bağımlı değişkenle bağımsız değişken arasındaki doğrusal ilişkiyi temsil eden bir doğru denklemi oluşturarak, bağımlı değişkeni tahmin etme problemini modelleyen bir regresyon yöntemidir.

Bu algoritma, veri setinin nümerik olarak düzenlenmiş öznitelikleri ile kalp hastalığı riski arasındaki lineer ilişkiyi analiz eder.

Tablo 2’de lineer regresyon modeli için 10 kat çapraz doğrulama test parametreleri gösterilmektedir.

Tablo 2. Lineer Regresyon Modeli 10 kat çapraz doğrulama parametreleri.

Table 2. Linear Regression Model 10-fold cross validation parameters.

Parametre	Değer
Sınıflandırıcı	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4
İlişki	heart (3) – nümerik
Örnek Sayısı	918
Öznitelik sayısı	11
Öznitelikler	Yaş, Cinsiyet, Göğüs Ağrısı Türü, Dinlenme Kan Basıncı, Kolesterol, Açlık Kan Şekeri, İstirahat EKG Sonuçları, Maksimum Kalp Atış Hızı, Egzersiz Bağlı Anjina, ST segment depresyonu, ST eğiminin yönü
Test Modu	10 kat çapraz doğrulama

Tablo 3’te lineer regresyon modeli öznitelikleri ve katsayıları verilmiştir.

Tablo 4’te lineer regresyon algoritması performans ölçütleri ve değerleri verilmiştir.

Bu algoritmada kalp hastalığı bağımlı değişkenini tahminlemek amacıyla Tablo 3’te, veri setinde bulunan “cinsiyet, göğüs ağrısı tipi, kolesterol, açlık kan şekeri, maksimum kalp atış hızı, egzersize bağlı anjina, ST segment depresyonu ve ST eğiminin yönü” olmak üzere 8 adet bağımsız değişken kullanılmıştır. Oluşturulan lineer denklemde “yaş, dinlenme kan basıncı ve istirahat EKG sonuçları” bağımsız değişkenlerinin kalp hastalığı bağımlı değişkenini etkilemediği görülmektedir. Bununla

birlikte veri setinde elde edilen korelasyon katsayısı değeri olan 0.7103 ile kalp hastalığını tahminlemede %71.03 oranında doğru sonuca ulaşıldığı Tablo 4’te gösterilmektedir.

Tablo 3. Lineer Regresyon Modeli Detayları.

Table 3. Linear Regression Model Details.

Öznitelikler	Katsayı
Cinsiyet	0.1643
Göğüs Ağrısı Tipi	0.1089
Kolesterol	-0.0004
Açlık Kan Şekeri	-0.0015
Maksimum Kalp Atış Hızı	-0.0018
Egzersiz Anjina	0.1782
ST Segment Depresyonu	0.052
ST Eğimi	0.2277
Kesme Noktası	-0.2684
Model Kurma Süresi	0.09 saniye

Tablo 4. Lineer regresyon algoritması performans değerleri.

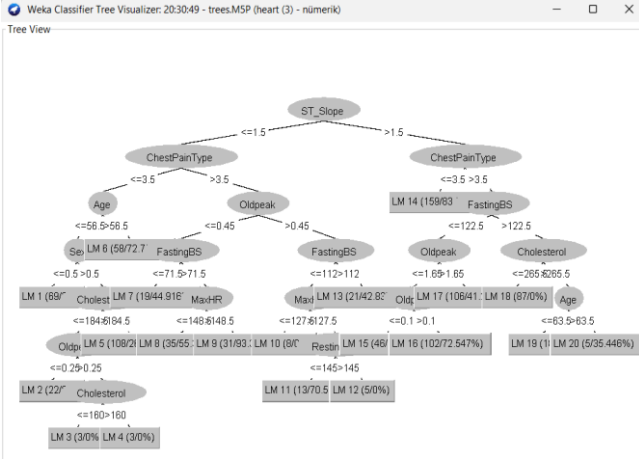
Table 4. Linear regression algorithm performance values.

Ölçüt	Değer
Korelasyon Katsayısı	0.7103
Ortalama Mutlak Hata	0.273
Hataların Karelerinin Ortalamasının Karekökü	0.35
Göreceli Ortalama Mutlak Hata	55.2131%
Göreceli Mutlak Hatanın Karekökü	70.3696%
Toplam Örnek Sayısı	918

#### 2.1.1.2 M5P Algoritması

M5P, karar ağaçları kullanarak regresyon problemini çözen algoritmalarından biridir. Bu algoritma, veri setindeki öznitelikleri kullanarak karmaşık ilişkileri modeller. Her bir yaprak düğümünde bir lineer model içerir, bu da bireylerin kalp hastalığı ritmini tahmin etmede daha fazla esneklik sağlar [18].

M5P algoritması ile farklı opsiyonlara göre 20 farklı lineer model oluşturulmuş ve bu modellerin detayları Şekil 2’de gösterilmiştir.



Şekil 2. M5P Ağaç Görselleştirici Ekranı.

Figure 2. M5P Tree Visualizer Screen.

Tablo 5'te M5P algoritmasına ait korelasyon katsayısı ve hata oranları verilmiştir.

Tablo 5. Korelasyon Katsayısı ve Hata Oranları.

Table 5. Correlation Coefficient and Error Rates.

Ölçüt	Değer
Korelasyon Katsayısı	0.7431
Ortalama Mutlak Hata	0.2122
Hataların Karelerinin Ortalamasının Karekökü	0.3335
Göreceli Ortalama Mutlak Hata	42.9076%
Göreceli Mutlak Hatanın Karekökü	67.0552%
Toplam Örnek Sayısı	918

Oluşturulan bu lineer modellere dayanarak, Tablo 5' te verilen M5P algoritması ile elde edilen sonuçlara göre korelasyon katsayısı 0.7431 olarak elde edilmiştir. Bu değer kalp hastalığı tahminlemede %74.31 oranında doğru sonuca ulaşıldığını ifade etmektedir.

## 2.1.2 Sınıflandırma Algoritmaları

Sınıflandırma, veri setindeki bireyleri belirli sınıflara atayan bir makine öğrenmesi yöntemidir. Bu kısımda, kalp hastalığı teşhisinde kullanılan sınıflandırma algoritmalarının temel prensipleri ve performansları detaylandırılacaktır. Bu algoritmalarından LibSVM ve IBK algoritmaları incelenmiştir. LibSVM, özellikle destek vektör makinelerinin (Support Vector Machine (SVM)) gücünü kullanarak doğrusal ve doğrusal olmayan ilişkileri modelleme konusunda etkili olurken, IBK komşuluk tabanlı yaklaşımıyla benzer özniteliklere sahip bireyleri gruplandırma konusunda etkili bir algoritmadır. Bu algoritmaların başarı oranları, sınıflandırma performanslarını değerlendirmek ve en etkili yöntemi belirlemek amacıyla karşılaştırılmıştır.

### 2.1.2.1 LibSVM Algoritması

LibSVM, destek vektör makineleri (SVM) kullanarak sınıflandırma problemlerini çözen bir algoritmadır. Bu algoritma, veri setindeki öznitelikleri kullanarak bireyleri kalp hastası veya sağlıklı olarak sınıflandırmak için bir karar sınırı oluşturur. LibSVM, yüksek boyutlu veri setlerinde etkili bir performans sağlayabilir ve özellikle doğrusal olmayan ilişkileri modelleme konusunda güçlüdür [19]. Tablo 6'da LibSVM algoritması Kappa istatistiği ve hata değerleri verilmiştir.

Tablo 6. LibSVM Algoritması Genel Sonuçlar.

Table 6. LibSVM Algorithms General Results.

Ölçüt	Değer
Doğru Sınıflandırılan Örnek Sayısı	792 (86.2745%)
Kappa İstatistiği	0.7205
Ortalama Mutlak Hata	0.1373
Hataların Karelerinin Ortalamasının Karekökü	0.3705
Göreceli Ortalama Mutlak Hata	27.7666%
Göreceli Mutlak Hatanın Karekökü	74.5216%
Toplam Örnek Sayısı	918

Tablo 7' de LibSVM algoritması hata oranları yer almaktadır.

Tablo 7 ve Tablo 9'da TP; Doğru pozitif oranı, FP; Yanlış pozitif oranı ve MKK; Matthews korelasyon katsayısı olarak ifade edilmiştir.

Tablo 7. Hata Oranları.

Table 7. LibSVM Algorithm Error Rates.

Sınıf	TP	FP	Kesinlik	Duyarlılık	F-Skoru	MKK	ROC Alanı	PRC Alanı
Sağlıklı	0.812	0.096	0.872	0.812	0.841	0.722	0.858	0.792
Kalp hastası	0.904	0.188	0.856	0.904	0.879	0.722	0.858	0.827
Ağırlıklı Ort.	0.863	0.147	0.863	0.863	0.862	0.722	0.858	0.811

Tablo 8'de ise LibSVM algoritmasının karmaşıklık matrisi gösterilmiştir.

Tablo 8. Karmaşıklık Matrisi.

Table 8. Confusion Matrix.

Gerçek \ Sınıflandırılan	sağlıklı (a)	kalp hastası (b)
Sağlıklı (a)	333	77
Kalp hastası (b)	49	459

Tablo 8'e göre gerçekte sağlıklı olan ve "sağlıklı" olarak sınıflandırılan örnek sayısı 333, gerçekte sağlıklı olup "kalp hastası" diye sınıflandırılan örnek sayısı 77, gerçekte kalp hastası olup "sağlıklı" diye sınıflandırılan örnek sayısı 49, gerçekte kalp hastası olup "kalp hastası" diye sınıflandırılan örnek sayısı 459 dur. Bu ise sağlıklı sınıflandırılması gereken 410 veriden 333'ünün doğru bir şekilde sağlıklı, 77'sinin ise yanlış bir şekilde kalp hastası olarak sınıflandırıldığı, kalp hastası olarak sınıflandırılması gereken 508 veriden ise 459'unun doğru bir şekilde kalp hastası, 49'unun ise yanlış bir şekilde sağlıklı olarak sınıflandırıldığını göstermektedir. Böylece algoritma 918 adet verinin 792'sini doğru bir şekilde tanımlayarak %86.2745'lik bir başarı oranına ulaşmıştır.

### 2.1.2.2 IBK Algoritması

IBK, bir bireyin sınıfını belirlemek için çevresindeki k en yakın komşusuna dayanan bir sınıflandırma algoritmasıdır. Bu algoritma, veri setindeki bireyleri benzer özelliklere sahip olanlarla gruplandırır. IBK, veri setindeki lokal ilişkileri ele alır ve bu sayede karmaşık yapıları modelleme yeteneği vardır. Ancak, veri setinin boyutu arttıkça başarı oranı azalabilir [19].

Aşağıdaki tablolarda IBK algoritmasından elde edilen sonuçlar, sınıf bazında detaylı doğruluk ve karmaşıklık matrisi ile verilmiştir.

Tablo 9. IBK Genel Sonuçlar.

Table 9. IBK General Results.

Ölçüt	Değer
Doğru Sınıflandırılmış Örnekler	795 (86.6013%)
Kappa İstatistiği	0.7282
Ortalama Mutlak Hata	0.2133
Hataların Karelerinin Ortalamasının Karekökü	0.327
Göreceli Ortalama Mutlak Hata	43.1517%
Göreceli Mutlak Hatanın Karekökü	65.7667%
Toplam Örnek Sayısı	918

Tablo 9'a göre IBK algoritması, toplamda 918 değerini 795'ini doğru bir şekilde tanımlayarak %86.6013'lük bir başarı oranına ulaşmıştır.

Tablo 10. Sınıf Bazında Detaylı Doğruluk.

Table 10. Detailed Accuracy by Class.

Sınıf	TP	FP	Kesinlik	Duyarlılık	F-Skoru	MKK	ROC Alanı	PRC Alanı
Sağlıklı	0.937	0.110	0.860	0.937	0.896	0.728	0.920	0.907
Kalp hastası	0.944	0.029	0.971	0.900	0.934	0.728	0.920	0.907
Ağırlıklı Ortalama	0.866	0.0866	0.866	0.866	0.920	0.728	0.920	0.907

Tablo 11. Karmaşıklık Matrisi.

Table 11. Confusion Matrix.

Gerçek \ Sınıflandırılan	Sağlıklı (a)	Kalp hastası (b)
Sağlıklı (a)	343	67
Kalp hastası (b)	56	452

Tablo 11'de verilen karmaşıklık matrisine göre 343 birey sağlıklı olup sağlıklı olarak sınıflandırılmış, 29 birey ise sağlıklı olduğu halde kalp hastası olarak sınıflandırılan örnek sayısını gösterir. Ayrıca 56 kişi kalp hastası olup sağlıklı olarak sınıflandırılan, 452 kişi ise kalp hastası olup kalp hastası olarak sınıflandırılan örnek sayısını gösterir. Karmaşıklık matrisi analizi, algoritmanın hangi durumları ne kadar doğru veya yanlış sınıflandırdığını ayrıntılı bir şekilde ortaya koymaktadır.

918 değer ve 11 özneliği içeren veri seti, IBK algoritması ile 7 en yakın komşu sayısı ile test edildiğinde optimum sonuç vermiştir.

### 2.1.3 Kümeleme Algoritmaları

Kümeleme, veri setindeki benzer özelliklere sahip bireyleri gruplandırma işlemidir. Bu kısımda, iki farklı kümeleme algoritması olan X-Means ve Beklenti Maksimizasyonu(BM) algoritmalarının, temel prensipleri ve kalp hastalığı teşhisindeki performansları incelenecektir. Her iki kümeleme algoritması da, kalp hastalığı teşhisindeki bireyleri benzer özelliklere sahip kümeler içinde gruplandırmak amacıyla kullanılmıştır. X-Means, küme sayısını otomatik olarak belirleme yeteneği ile dikkat çekerken, BM karmaşık veri yapılarını modelleme konusunda daha esnek bir yaklaşım sunmaktadır. Bu algoritmaların performansları, kalp hastalığı teşhisinde kümeleme algoritmalarının potansiyelini vurgulamakta ve gelecekteki benzer çalışmalar için bir temel oluşturmaktadır.

#### 2.1.3.1 X-Means Algoritması

X-Means, K-Means algoritmasının genişletilmiş bir versiyonudur ve veri setindeki gizli yapıları modellemek için kullanılır. Bu algoritma, küme sayısını otomatik olarak belirlemeye çalışır. X-Means, her bir kümenin içindeki varyansı değerlendirir ve küme sayısını ayarlamak için bir bilgi kriterini kullanır [20].

Tablo 12’de X-Means algoritmasının kümelenmiş örneklerinin sayısı ve oranları görülmektedir.

Tablo 12. Kümelenmiş Örneklerin Dağılımı.

Table 12. Distribution of Clustered Samples.

Küme	Örnek Sayısı	Oran (%)
Kalp hastası 0	417	45%
Sağlıklı 1	501	55%
Toplam	918	100%

Tablo 12’ ye göre, 0 numaralı kümede 417 ve 1 numaralı kümede 501 veri olduğu görülmektedir. Bu duruma göre, toplam 918 verinin %45’i 0 numaralı kümede, %55’i ise 1 numaralı kümede yer almıştır.

Tablo 13’te X-Means algoritması ile Küme 0, “kalp hastası” ağırlıklı olarak, Küme 1, “sağlıklı” ağırlıklı olarak etiketlenmiştir.

Tablo 13. Sınıf-Küme Dağılımı.

Table 13. Class-Cluster Distribution.

	Küme 0 (kalp hastası)	Küme 1 (sağlıklı)	Toplam
Sağlıklı	52	358	410
Kalp hastası	365	143	508

Tablo 13 incelendiğinde “Sağlıklı” sınıfına ait 52 veri “0” numaralı kümede, 358 veri ise “1” numaralı kümede bulunmaktadır. “Kalp hastası” sınıfına ait 365 verinin “0” numaralı kümede, 143 verinin ise “1” numaralı kümede olduğu belirlenmiştir. Algoritma, “0” numaralı küme için “kalp hastası” ve “1” numaralı küme için “sağlıklı” sınıfını belirlemiştir. Bu duruma göre, “0” numaralı kümede tanımlanan 52 “sağlıklı” verisi ile “1” numaralı kümede tanımlanan 143 “kalp hastası” verisi yanlış kümelenmiş veriler olup toplamda 195 adettir. Bu durum Tablo 14’te yanlış kümelenen örnekler ve oranı olarak verilmiştir.

Tablo 14. Yanlış Kümelenen Örnekler.

Table 14. Incorrectly Clustered Examples.

Ölçüt	Değer
Yanlış Kümelenen Örnek Sayısı	195
Yanlış Kümelenme Oranı	21.2418%

Buna göre toplam 918 verinin 195’i yanlış kümelenerek %21.2418’lik bir hata oranı ve %78.7582’lik bir başarı oranı elde edilmiştir.

### 2.1.3.2 Beklenti Maksimizasyonu (BM) Algoritması

Beklenti Maksimizasyonu (Expectation-Maximization, EM) karmaşık veri setlerinde gizli yapıları modelleme konusunda kullanılan bir kümeleme algoritmasıdır. BM, iki temel adımdan oluşur. Bunlar Beklenti(Expectation) ve Maksimizasyon (Maximization) adımlarıdır. Algoritma, veri setindeki gizli parametreleri tahmin etmek ve küme merkezlerini güncellemek için bu iki adımı sırayla tekrarlar, esnek bir

modelleme yeteneği sunar ve özellikle gizli ilişkileri anlamak için kullanılır [20]. Şekil 3’te BM algoritmasının 2 küme için görselleştirilmesi verilmektedir.



Şekil 3. BM Algoritması 2 küme sayısına göre görselleştirilmesi

Figure 3. EM Algorithm 2 visualization by number of clusters.

Şekil 3’ te mavi renk ile işaretlenen verilerin 0 numaralı küme, kırmızı renk ile gösterilen verilerin ise 1 numaralı küme olarak belirlenmiştir. Kare şeklinde simgelenen veriler hatalı kümelenmiş verileri temsil ederken, çarpı işareti ile gösterilen veriler algoritmanın doğru tanımladığı verileri ifade etmektedir. Şekil 3 belirli bir hata oranı ile algoritmanın doğru ve yanlış kümelenmiş verileri ayırt ettiğini göstermektedir. Kare ve çarpı simgeleri, algoritmanın performansını değerlendirmek için kullanılan doğru ve yanlış sınıflandırılmış verilerin görsel temsilini sağlamaktadır.

## 3 Performans Ölçütleri

Bu bölümde, makine öğrenmesi yöntemlerinin performansını kapsamlı bir biçimde ölçmek amacıyla kappa istatistiği, korelasyon katsayısı, ortalama mutlak hata, hataların karelerinin ortalamasının karekökü, göreceli mutlak hata, göreceli mutlak hatanın karekökü, kesinlik, duyarlılık, F-skoru, AUC eğrisi (alıcı işlem karakteristikleri) ve PRC alanı (Kesinlik Duyarlılık Eğrisi altında kalan alan) gibi çeşitli performans ölçütlerinden kısaca bahsedilerek, performans ölçütleri tabloları ile verilecektir.

Kappa istatistiği, bir değerlendirici veya gözlemcinin iki kategori arasındaki uyumu değerlendirmek için kullanılan istatistiksel bir ölçüttür.  $P_r(a)$ , iki değerlendirici arasındaki gözlemlenen uyum oranını ve  $P_r(e)$ , şansa bağlı olarak beklenen uyum oranını ifade etmek üzere, iki değişken arasındaki uyumu ölçerken,  $P_r(a)$  ve  $P_r(e)$  olasılıkları üzerinden Cohen’in Kappa İstatistiği (Kİ), (1) numaralı formülle hesaplanır.

$$K = \frac{P_r(a) - P_r(e)}{1 - P_r(e)} \quad (1)$$

Bu formül, kappa istatistiğini hesaplarken gözlemlenen uyumu şansa bağlı uyumdan çıkartarak düzeltmeye olanak tanır. Elde edilen kappa değeri -1 ile +1 arasında değişir. 0’dan küçük bir değer uyumun olmadığını, 1’e yaklaşan bir değer ise tam uyumu gösterir. Kappa değeri ne kadar yüksekse, değerlendiriciler arasındaki uyum o kadar güçlüdür.

Korelasyon katsayısı iki değişken arasındaki ilişkiyi ölçen ve ilişkinin yönü ile gücünü belirleyen bir istatistiksel ölçüttür. Değer genellikle -1 ile +1 arasında değişir ve bu değer, ilişkinin

doğasını anlamak için kullanılır. Korelasyon katsayısı +1'e yaklaşıyorsa, iki değişken arasında kuvvetli bir pozitif ilişki vardır. Korelasyon katsayısı -1'e yaklaşıyorsa, iki değişken arasında kuvvetli bir negatif ilişki vardır. Korelasyon katsayısı 0'a yaklaşıyorsa, iki değişken arasında belirgin bir ilişki yoktur veya ilişki çok zayıftır.  $x_i$ , birinci değişkenin i. gözlem değerini,  $y_i$ , ikinci değişkenin i. gözlem değerini, n ise toplam gözlem sayısını ifade etmek üzere, Korelasyon Katsayısı (KK), (2) numaralı formülle hesaplanır.

$$KK = \frac{\sum_{i=1}^n x_i y_i - \frac{(\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n}}{\sqrt{\left(\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}\right) \left(\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n}\right)}} \quad (2)$$

Burada tahminde tam başarı elde edilebilmesi için, tahmin hatasının sifıra eşit olması beklenir. Fakat bu durum gerçekte çok nadir ortaya çıkar.

Eşitlik (3)-(4)-(5)'te; "n" örneklem sayısını, "i" örneklem sırasını, " $\theta_i$ " i. gözlemdeki gerçek değeri, " $\hat{\theta}_i$ " i. gözlemdeki tahmin edilen değeri ve " $\theta$ " gerçek değerlerin ortalamasını ifade etmek üzere, Ortalama Mutlak Hata (OMH) Eşitlik (3)'te

$$(OMH) = \frac{1}{n} \sum_{i=1}^n |\hat{\theta}_i - \theta_i| \quad (3)$$

formülü ile verilir.

Bir diğer hata ölçütü Hataların Karelerinin Ortalamasının Kareköküdür (HKOK) ve Eşitlik (4)'teki formül ile hesaplanır.

$$(HKOK) = \sqrt{\frac{\sum_{i=1}^n (\hat{\theta}_i - \theta_i)^2}{n}} \quad (4)$$

Tahmin edilen değerlerle gerçek değerler arasındaki mutlak hataların, basit bir referans modeline, göre ne kadar büyük veya küçük olduğunu görebilmek için Göreceli Mutlak Hata (GMH) ölçütü kullanılır. Eşitlik (5) aracılığıyla hesaplanır.

$$(GMH) = \frac{\sum_{i=1}^n |\hat{\theta}_i - \theta_i|}{\sum_{i=1}^n |\theta - \theta_i|} \quad (5)$$

Buradaki göreceli mutlak hata yapılan tahminin gerçek değerlerle olan yakınlığını izlemenin bir yoludur.

Tahmin hatasını izlemede kullanılan bir başka yol da Göreceli Mutlak Hatanın Kareköküdür (GMHK) ve Eşitlik (6) ile hesaplanır

$$(GMHK) = \sqrt{\frac{\sum_{i=1}^n (\hat{\theta}_i - \theta_i)^2}{\sum_{i=1}^n (\theta - \theta_i)^2}} \quad (6)$$

Bu çalışmada, gerçek değeri pozitif olup pozitif olarak tahmin edilenler doğru pozitif "DP", gerçek değeri pozitif olup negatif olarak tahmin edilenler yanlış negatif "YN", pozitif olarak tahmin edilmiş fakat gerçek değeri negatif olanlar yanlış pozitif "YP" ve negatif olarak tahmin edilmiş ve gerçek değeri negatif olanlar da doğru negatif "DN" olarak tanımlanmıştır. Eşitlik (7)'de DP Oranı ve Eşitlik (8)'de YP Oranı formülleri verilmiştir.

$$DP \text{ Oranı} = \frac{DP}{(DP+YN)} \quad (7)$$

$$YP \text{ Oranı} = \frac{YP}{(YP+DN)} \quad (8)$$

Weka programı özellikle DP ve YP değerlerini hem her bir kategori için oranlarını hem de tüm kategoriler için ağırlıklı ortalama sonucunu hesaplamaktadır. Performans analizi yapılırken ağırlıklı ortalama sonuçlar dikkate alınmıştır.

Kesinlik skoru, modelin pozitif olarak tahmin ettiği örneklerin gerçekte pozitif olma oranını ölçen parametredir. Formül Eşitlik (9)'da verilmiştir.

$$\text{Kesinlik (p)} = \frac{DP}{(DP+YP)} \quad (9)$$

Sınıflandırma modelinin performansını değerlendirmek için kullanılan hassasiyet, modelin pozitif olarak tahmin ettiği örneklerin gerçekte pozitif olma oranını ölçer. Bu formül Eşitlik (10)'da verilmiştir.

$$\text{Hassasiyet(r)} = \frac{DP}{(DP+YN)} \quad (10)$$

Kesinlik(precision) ve hassasiyet(recall), bir modelin performansını değerlendirmek için yaygın olarak kullanılır. Ancak, bu ölçütler tek başına yeterli değildir ve genellikle birlikte değerlendirilir. Bu bağlamda, F-skoru devreye girer. F-skoru, kesinlik ve hassasiyetin harmonik ortalamasını temsil eder ve bu sayede her iki ölçütü birleştirerek daha kapsamlı bir performans değerlendirmesi sağlar. F-skoru, Eşitlik (11)'deki formülle hesaplanır.

$$F - \text{skoru} = 2 \frac{\text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} = 2 \frac{pr}{p+r} \quad (11)$$

DP Oranı ile YP Oranlarının bir grafik üzerine yerleştirilmesi ile Alıcı işlem karakteristikleri (AİK) denilen ROC eğrileri (Receiver Operating Characteristic) oluşturulur. Bu eğrilerde DP Oranı 1'e yaklaştıkça daha iyi tahminler elde edilirken YP Oranı 0'a yaklaştıkça daha az hatalı tahminler elde edildiği bilinmektedir. Grafiğin altında kalan alan (AİK) alanı olarak ifade edilir ve bu alan ne kadar büyükse o kadar başarılı bir sınıflandırma olduğu söylenebilir.

Hassasiyet ve kesinlik değerleri, çeşitli eşik değerler veya parametreler kullanılarak hesaplanır ve bir grafik üzerinde gösterilir. Bu grafiğe, Kesinlik-Hassasiyet Eğrisi (KHE) (Precision-Recall Curve, PRC) adı verilir. Bu eğrinin altında kalan alana ise (KHE) Alanı (PRC Area ya da AUC-PR) denir. KHE Alanı değerinin 1'e yaklaşması, modelin hem yüksek



hassasiyet hem de yüksek kesinlikle çalıştığını, dolayısıyla daha başarılı sonuçlar ürettiğini gösterir.

#### 4 Sonuçlar

Bütün bu performans ölçütleri ile kalp hastalığının tespiti için kullanılan algoritmaların başarımlarını toplu halde gösteren Tablo 15 aşağıdaki şekildedir.

Tablo 15. Analiz edilen algoritmalar ve sonuçlar.

Table 15. Analyzed algorithms and results.

Ölçüt	Lineer Regresyon	M5P	IBK	LibSVM	X-Means	BM
Doğru Sınıflandırılmış Örnekler	71.03	74.31	86.6013	86.2745	-	-
Kappa İstatistiği	-	-	0.7282	0.7205	-	-
Korelasyon Katsayısı	0.7103	0.7431	0.866013	0.862745	-	-
(OMH)	0.273	0.2122	0.2133	0.1373	-	-
(HKOH)	0.35	0.3335	0.327	0.3705	-	-
(GOMH)	55.2131	42.9076	43.1517	27.7666	-	-
(GMHK)	70.3696	67.0552	65.7667	74.5216	-	-
DP Oranı	-	-	0.866	0.863	-	-
YP Oranı	-	-	0.14	0.147	-	-
Kesinlik	-	-	0.866	0.863	-	-
Hassasiyet	-	-	0.866	0.863	-	-
F-Skoru	-	-	0.866	0.862	-	-
(Alk) Alanı	-	-	0.92	0.858	-	-
(KHE) Alanı	-	-	0.907	0.811	-	-
Yanlış Kümelene Örnekler	-	-	-	-	21.2418	17.8649

Tablo 15'te X-Means ve BM sütunlarında denetimli öğrenme metrikleri yerine kümeleme sonuçları yer almaktadır. Diğer satırlarda veri olmadığı için "-" (boş) olarak belirtilmiştir.

Bu çalışma, kalp hastalığı teşhisinde kullanılan makine öğrenmesi algoritmalarının performans analizi üzerine odaklanmıştır. Sonuçlar, regresyon, sınıflandırıcı ve kümeleme algoritmalarının kullanıldığı üç farklı türdeki altı algoritmanın performansına göre belirlenmiştir.

Sınıflandırma algoritmaları, IBK(K-Nearest Neighbors) ve LibSVM, diğer algoritmalara göre daha yüksek doğruluk oranları elde etmiştir. IBK'nın %86.6 doğruluk oranı ve LibSVM'nin %86.3 doğruluk oranı, bu algoritmaların kalp hastalığı teşhisinde etkili ve güvenilir bir performans sergilediğini göstermektedir. Bu sonuçlar, sınıflandırıcı algoritmaların, veri setindeki özniteliklere dayalı olarak bireyleri başarılı bir şekilde sınıflandırma yeteneğini vurgulamaktadır.

Regresyon ve kümeleme algoritmalarının performansları da analiz edilmiş ancak sınıflandırma algoritmaları kadar yüksek doğruluk oranlarının elde edilemediği görülmüştür. Bu durum, kalp hastalığı teşhisinde sınıflandırma algoritmalarının daha etkili olabileceğini düşündürmektedir. Ancak kümeleme algoritmaları olan X-Means ve EM yine de kabul edilebilir doğruluk oranlarına sahip olmuştur.

Sonuç olarak, makine öğrenmesi algoritmalarının kalp hastalığı tespiti için kullanılabileceği önemli bir potansiyeli göstermektedir. Sınıflandırma algoritmaları, bu alanda öne çıkan ve başarılı sonuçlar elde eden algoritmalar olarak belirlenmiştir. Bu bulgular, gelecekteki klinik uygulamalar ve benzer çalışmalar için bir temel oluşturarak, makine öğrenmesi yaklaşımlarının kardiyovasküler sağlık alanında daha fazla benimsenmesine olanak sağlayabilir.

#### 5 Conclusion

In this section, the performance analysis of machine learning applications on heart disease diagnosis was examined and the results were compared using a total of six algorithms of three different types: regression, classifier and clustering algorithms using the Weka platform. In the analysis made using Linear Regression, M5P, IBK, LibSVM, X-Means, EM Algorithms, the results were examined according to the parameters on Weka. Table 15 shows the values of the parameters and algorithms on Weka.

This study focused on performance analysis of machine learning algorithms used in heart disease diagnosis. The results were determined according to the performance of six algorithms of three different types using regression, classifier and clustering algorithms.

Classification algorithms, IBK(K-Nearest Neighbors) and LibSVM, achieved higher accuracy rates than other algorithms. The 86.6% accuracy rate of IBK and the 86.3% accuracy rate of LibSVM show that these algorithms exhibit effective and reliable performance in diagnosing heart disease. These results highlight the ability of classifier algorithms to successfully classify individuals based on attributes in the data set.

The performances of regression and clustering algorithms were also analyzed, but it was observed that accuracy rates as high as classification algorithms could not be achieved. This suggests that classification algorithms may be more effective in diagnosing heart disease. However, the clustering algorithms X-Means and EM still had acceptable accuracy rates.

As a result, it demonstrates the significant potential that machine learning algorithms can be used for heart disease detection. Classification algorithms have been determined as the algorithms that stand out in this field and achieve successful

results. These findings may provide a foundation for future clinical applications and similar studies, enabling greater adoption of machine learning approaches in cardiovascular health.

## 6 Yazar Katkı Beyanı

Gerçekleştirilen çalışmada **Yazar 1**, fikrin oluşturulması, verilerin temini ve elde edilen sonuçların değerlendirilmesi başlıklarında, **Yazar 2**, literatür taraması, yazım denetimi ve makale revizyonu başlıklarında, **Yazar 3** içerik açısından makalenin kontrol edilmesi başlıklarında katkı sunmuşlardır.

## 7 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

## 8 Kaynaklar

- [1] Pushpawathi TP, Kumari S, Kubra NK. "Heart Failure Prediction by Feature Ranking Analysis in Machine Learning". 6th International Conference on Inventive Computation Technologies (ICICT), ss. 915-920, IEEE, 2021.
- [2] American Heart Association Statistics Committee and Stroke Statistics Subcommittee. "Executive summary: heart disease and stroke statistics-2016 update". A report from the American Heart Association, 133(4), 447-454, 2016.
- [3] Kumar NM, Mallick PK. "The Internet of Things: Insights into the building blocks, component interactions, and architecture layers". *Procedia Computer Science*, 132, 109-117, 2018.
- [4] Özmen T, Kuzu Ü, Koçyiğit Y, Sarnel H. "Metasezgisel yöntemlerle öznitelik sayısını azaltarak diyabetin erken dönemde tespiti". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(6), 596-606, 2023.
- [5] Çiftçi S, Batur Sir GD. "Acil servise başvuru sayısının zaman serisi analiz ve makine öğrenmesi yöntemleri ile tahmin edilmesine yönelik bir uygulama". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(7), 667-679, 2023.
- [6] Topol EJ. "High-performance medicine: the convergence of human and artificial intelligence". *Nature Medicine*, 25(1), 44-56, 2019.
- [7] Hall M, Frank E, Holmes G, Pfahringer B, Reutemann P, Witten IH. "The WEKA Data Mining Software: An Update. ACM SIGKDD". *Explorations Newsletter*, 11, 10-18, 2009.
- [8] Çifçi ME. Kalp hastalıklarında kullanılan yapay zeka teknikleri ve uygulamaları. Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, Konya, Türkiye, 2019.
- [9] Coşar M, Deniz E. "Makine Öğrenimi Algoritmaları Kullanarak Kalp Hastalıklarının Tespit Edilmesi". *Avrupa Bilim ve Teknoloji Dergisi*, 28, 1112-1116, 2021.
- [10] Mohan S, Thirumalai C, Srivastava G. "Effective Heart Disease Prediction Using Hybrid ML Techniques". *IEEE Access*, vol. 7, 2019.
- [11] Dipto I, Islam T, Rahman H, Rahman M. "Comparison of Different Machine Learning Algorithms for the Prediction of Coronary Artery Disease". *Journal of Data Analysis and Information Processing*, 8, 41-68, 2020.
- [12] Kim JK, Kang S. "Neural Network-Based Coronary Heart Disease Risk Prediction Using Feature Correlation Analysis". *Journal of Healthcare Engineering*, Volume 2017, Article ID 2780501, 2017.
- [13] Mohamed TS, Ali MH. "Heart Diseases Prediction Using WEKA." *Journal of Baghdad College of Economic Sciences*, issue no. 58, 2019.
- [14] Sen SK. "Predicting and Diagnosing of Heart Disease Using Machine Learning Algorithms". *International Journal of Engineering and Computer Science*, vol. 6, no. 6, pp. 21623-21631, June 2017.
- [15] KAGGLE. "Heart Failure Prediction Dataset". <https://www.kaggle.com/fedesoriano/heart-failure-prediction> (15.04.2023).
- [16] Gökhan A, Doğan N. "Veri Madenciliğinde Kullanılan Güncel Bir Analiz Programı: WEKA". *Journal Of Measurement and Evaluation in Education And Psychology*, 10(1), 80-95, 2019.
- [17] Siper M. Yapay Zeka Yöntemleriyle Üstyapı Performans Tahmini. Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi, Konya, Türkiye, 2021.
- [18] Kara Ş, Şamlı R. "Yazılım projelerinin maliyet tahmini için WEKA'da makine öğrenmesi algoritmalarının karşılaştırmalı analizi". *Avrupa Bilim ve Teknoloji Dergisi*, 23, 415-426, 2021.
- [19] Taşçı ME, Şamlı R. "Veri madenciliği ile kalp hastalığı tespiti". *Avrupa Bilim ve Teknoloji Dergisi*, 88-95, 2020.
- [20] Pat G. Araştırma projelerinde kümeleme ile çoklu analiz. Yüksek Lisans Tezi, Sakarya Üniversitesi, Türkiye, 2020.
- [21] Aydemir E. *Weka ile Yapay Zeka*. Birinci Baskı. Ankara, Türkiye, Seçkin Yayınevi, 2018.
- [22] Işık K, Ulusoy SK. "Determining the factors that affect the production time in metal industry utilizing data mining methods". *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(4), 1949-1962, 2021.