



# Kalp Yetmezliği Tanılı Hastaların Hayatta Kalma Tahmininde Topluluk Makine Öğrenme Yöntemlerinin Performans Analizi

## *Performance Analysis of Ensemble Machine Learning Methods for Predicting Survival of Patients with Heart Failure*

İrem Şenyer Yapıcı<sup>1\*</sup>, Rukiye Uzun Arslan<sup>2</sup>, Okan Erkaymaz<sup>3</sup>

<sup>1</sup>Zonguldak Bülent Ecevit Üniversitesi, Bilgisayar Mühendisliği Bölümü, Zonguldak, Türkiye

<sup>2</sup>Zonguldak Bülent Ecevit Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak, Türkiye

<sup>3</sup>Milli Savunma Üniversitesi, Deniz Harp Okulu, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

### Öz

Kalp yetmezliği önemli morbidite ve mortaliteye sahip bir kardiyovasküler hastalık olup, dünya çapında giderek daha fazla insanı etkilemektedir. Klinik verilerle kalp yetmezliği tanılı hastaların sağ kalımlarını tahmin etmek oldukça zordur. Bu çalışmada, kalp yetmezliği tanılı hastaların hayatta kalma tahmininin doğruluğunu artıracak önemli özellikler ve etkili makine öğrenme (MÖ) algoritması tespit edilerek, etkili ve verimli bir MÖ temelli bir yapay zeka modeli tasarlanmaya çalışılmıştır. Bunun için yedi farklı MÖ algoritmasının performansları veri setinden çıkarılan belirleyici özelliklere dayanarak karşılaştırılmıştır. Veri setindeki dengesizliği gidermek ve daha gerçekçi doğruluk değerine sahip modeller elde etmek için amacıyla sentetik azınlık aşırı örnekleme tekniği (SMOTE) ile iki farklı çapraz doğrulama tekniğinden yararlanılmıştır. Yapılan benzetim çalışmaları sonucunda SMOTE tekniğinin kalp yetmezliği tanılı hastaların hayatta kalma oranını tahmininde sınıflandırıcıların performanslarını önemli ölçüde arttırdığı tespit edilmiştir. Birisi dışarıda çapraz doğrulama tekniğinde rastgele orman algoritmasıyla %90'lık bir başarımla elde edilirken, 10 kat çapraz doğrulama tekniğinde ekstrem gradyan artırma algoritmasıyla %93 doğruluk değeriyle en yüksek başarımla elde edilmiştir. Elde edilen sonuçlar literatürde benzer veri seti kullanılarak yapılan çalışmalarla kıyaslandığında önerilen yöntemin daha yüksek performans sergilediği tespit edilmiştir. Önerilen yöntem hem sağlık sistemini iyileştirme hem de sağlık hizmeti sağlayıcıları için kalp yetmezliği tanılı hastaların hayatta kalmasını tahmininde etkili bir yöntem olma potansiyeli bulunmaktadır. Bununla birlikte uzman hekimlere kalp yetmezliği tanılı hastaların tedavi sürecinin planlanmasında yol gösterici olacaktır.

**Anahtar Kelimeler:** Kalp yetmezliği, makine öğrenmesi, özellik seçimi, SMOTE

### Abstract

Heart failure is a cardiovascular disease with significant morbidity and mortality, affecting an increasing number of people worldwide. It is very difficult to predict the survival of patients diagnosed with heart failure using clinical data. In this study, an intelligent machine learning (ML)-based artificial intelligence model is designed by identifying important features and an effective ML algorithm that will improve the accuracy of survival prediction of patients diagnosed with heart failure. For this purpose, the performance of seven different ML algorithms were compared regarding the extracted features from the dataset. Synthetic minority oversampling technique (SMOTE) and two different cross-validation techniques were used to remove the imbalance in the dataset and to obtain models with more realistic accuracy. Experimental results showed that SMOTE technique significantly improve the performance of classifiers in predicting the survival rate of patients diagnosed with heart failure. In the one-out cross-validation technique, the random forest algorithm achieved 90% accuracy, while in the 10-fold cross-validation technique, the extreme gradient boosting algorithm achieved

\*Sorumlu yazarın e-posta adresi: [senyerirem@gmail.com](mailto:senyerirem@gmail.com)

İrem Şenyer Yapıcı [orcid.org/0000-0003-0655-340X](https://orcid.org/0000-0003-0655-340X)

Rukiye Uzun Arslan [orcid.org/0000-0002-2082-8695](https://orcid.org/0000-0002-2082-8695)

Okan Erkaymaz [orcid.org/0000-0002-1996-8623](https://orcid.org/0000-0002-1996-8623)



the highest performance with 93% accuracy. When the results obtained are compared with the studies conducted in the literature used similar data sets, it is found that the proposed method exhibits higher performance. The proposed method has the potential to both improve the healthcare system and be an effective method for healthcare providers in predicting the survival of patients diagnosed with heart failure. In addition, it will guide specialist physicians in planning the treatment process of patients diagnosed with heart failure.

**Keywords:** Heart failure, machine learning, feature selection, SMOTE.

## 1. Giriş

Dünya Sağlık Örgütü (DSÖ) verilerine göre, dünya çapında meydana gelen ölümlerde en büyük pay kardiyovasküler hastalıklara (KVH) aittir (WHO 2023). KVH; aritmiler, kalp yetmezliği, hipertansif hastalıklar, romatizmal kalp hastalıkları ve periferik damar hastalıkları gibi birçok kalp ve damar hastalığını içermektedir (WHO 2023, Meng vd. 2019, Çilhoroz ve Çilhoroz 2021). Bunlardan kalp yetmezliği (KY), kalbin vücudun ihtiyaç duyduğu kan miktarını karşılayamaması ile karakterize edilen ve karmaşık klinik belirtileri olan bir sendromdur (Muntasir Nishat vd. 2022). KY'nin ortaya çıkmasına neden olabilecek başlıca risk faktörleri arasında koroner arter hastalığı, hipertansiyon, diyabet, kalp kapak hastalıkları, obezite, tütün kullanımı, fiziksel inaktivite, yaş, cinsiyet ve aile geçmişi yer almaktadır (Yancy vd. 2013, TDK 2023). Her geçen yıl prevalansı artan KY'nin önümüzdeki 15-20 yıl içerisinde halk sağlığını daha da tehdit edici boyutlara ulaşacağı öngörülmektedir (TKD 2023). Bu bağlamda KY'nin erken evrelerde teşhis edilerek tedaviye başlanması, hastalığın mortalite ve morbiditesinin azaltılmasında önemlidir.

KY teşhisinin konulmasında net bir yöntem olmamakla birlikte; ilk olarak hastanın klinik geçmişi uzman hekimler tarafından değerlendirilmektedir (Shamsham ve Mitchell 2000). Bunun yanı sıra hastaya elektrokardiyografi, eko-kardiyografi ve göğüs röntgeni başta olmak üzere pek çok elektrofizyolojik test uygulanmaktadır (Chiarugi vd. 2008). Ancak analiz edilmesi ve yönetilmesi gereken veri ve bilgilerin miktarı ve karmaşıklığı, KY'nin doğru teşhis edilmesini ve tedavi yöntemlerinin değerlendirilmesini oldukça zorlu ve karmaşık süreçlere dönüştürmektedir (Tripoliti vd. 2017, Takcı 2023). Bu durum son yıllarda makine öğrenme (MÖ) tekniklerinin karmaşık tıbbi verilerin analizinde, hastalığın seyrinin takibinde, hastalık sonucunun kestiriminde ve hastalıkların sınıflandırılmasında tercih edilmesindeki dikkat çekici artışının nedenleri arasındadır (Solanki ve Sharma 2019, Salman ve Aksoy 2022, Takcı 2023, Gürgen ve Serttaş 2023). Literatürde KY tanı ve prognozu (öngörüsü) hususunda MÖ tekniklerine dayalı çok sayıda çalışma bulunmaktadır (Saqlain vd. 2016, Ali vd. 2019, Chicco ve Jurman 2020, Erdaş ve Ölçer 2020, Oladimeji ve Oladimeji 2020,

Rahayu vd. 2020, Gürfidan ve Ersoy 2021, Ishaq vd. 2021, Potur ve Erginel 2021, Huang vd. 2021, Türkmenoğlu ve Yıldız 2021, Mamun vd. 2022, Muntasir Nishat vd. 2022, Özbay ve Özbay 2022, Salman ve Aksoy 2022, Keser ve Keskin 2023, Gürgen ve Serttaş 2023). Örneğin, Örneğin, Saqlain vd. (2016) KY tanısı konan hastaların sağkalımlarını tahmin etmek için uzmanların yardımıyla tespit ettikleri özellikleri kullanarak çoklu bir sınıflandırma yaklaşımı önermişlerdir. Farklı sınıflandırma algoritmalarının kullanıldığı çalışmada en yüksek başarımla Naive Bayes (NB) (%86,7) algoritmasıyla elde edilmiştir. Ali vd. (2019) KY hastalığının teşhis doğruluğunu arttırmak amacıyla ki-kare istatistiksel testi ve Gauss Navie Bayes (GNB) sınıflandırıcı temelli iki aşamalı özellik odaklı bir karar destek sistemi önermişlerdir. Altı farklı değerlendirme ölçütüne göre değerlendirilen modelin performansının geleneksel GNB modelinin performansına kıyasla daha fazla olduğu tespit edilmiştir. Chicco ve Jurman (2020) çalışmalarında hem KY olan hastaların sağkalımını tahmin etmek hem de KY'deki en önemli risk faktörlerine karşılık gelen özellikleri belirlemek amacıyla farklı MÖ tekniklerinden yararlanmışlardır. Yaptıkları çalışmada MÖ algoritmalarıyla tespit edilen risk faktörlerinin geleneksel biyoistatistik testlerle belirlenenlerle kıyaslanmıştır. Yapılan analizler sonucunda serum kreatinin ve ejeksiyon fraksiyonunun tıbbi kayıtlardan KY hastalarının sağkalımını tahmin etmede daha yüksek başarıma sahip olduğunu belirlenmiştir. Bu iki özellik kullanılarak KY olan hastaların sağkalımını tahmininde lojistik regresyon (LR) sınıflandırıcısıyla %83,8'lik bir doğruluk elde edilmiştir. Erdaş ve Ölçer (2020) KY tanılı hastaların sağkalımlarını tahmin edebilmek amacıyla geliştirdikleri MÖ tabanlı modellerden tüm özelliklerin kullanılması durumunda %86 ile bir kural (one rule) algoritmasıyla elde etmişlerdir. Oladimeji ve Oladimeji (2020), KY hastalarının sağkalımını tahmin etmek için MÖ tabanlı bir yöntem önermişlerdir. Önerilen yöntemde spesifik (belirleyici) özellikler sıralamalarına göre seçilerek, sınıflandırma veri kümesindeki sınıf dengesizliğinin üstesinden gelinmiştir. Farklı MÖ algoritmalarının kullanıldığı çalışmada en yüksek başarımla %83,18 ile rasgele orman (RO) algoritmasıyla elde edilmiştir. Bir başka çalışmada sentetik azınlık aşırı örnekleme tekniği (SMOTE) ve yeniden örnekleme tekniklerinin RO, karar ağaçları (KA), k en yakın komşu (KNN),

destek vektör makineleri (DVM), yapay sinir ağları (YSA) ve NB algoritmalarının KY hastalarının sağkalımını tahmin etme performansları üzerindeki etkileri araştırılmıştır. Yapılan analizler sonucunda her iki örnekleme tekniği için en yüksek başarımları sergileyen algoritmanın RO algoritması olduğu tespit edilmiştir (Rahayu vd. 2020). Gürfidan ve Ersoy (2021) hastaların klinik verileri ve yaşam bilgilerine dayanarak, KY'ne bağlı ölüm durumlarının sınıflandırılmasında kullandıkları farklı MÖ algoritmalarından en yüksek başarımların DVM'yle elde edildiğini ortaya koymuşlardır. Ishaq vd. (2021) KY hastalarının sağkalım tahmininde ekstra ağaç sınıflandırıcısının (ETC) daha iyi performans sergilediğini ve sınıflandırıcısının performansının SMOTE ile 0,9262 doğruluk değerine ulaştığını göstermişlerdir. Potur ve Erginel (2021) üç farklı öznelik seçim yöntemi kullanarak farklı MÖ algoritmalarının sınıflandırma performanslarını karşılaştırdıkları çalışmalarında, çok katmanlı yapay sinir ağı algılayıcısının (ÇKYSA) %90'lık doğruluk oranıyla en yüksek başarımları elde ettiğini saptamışlardır. Huang vd. (2021) KY'ni sınıflandırmak amacıyla kullandıkları NB, DVM, RO ve LR algoritmalarından RO'nun %88 doğrulukla en yüksek performansa sahip olduğu ortaya koymuşlardır. Türkmenoğlu ve Yıldız (2021) farklı yeniden örnekleme yöntemleri kullanarak KY tanılı hastaların sağkalımlarının tahmininde kNN, RO ve EA algoritmalarının başarımlarını araştırmışlardır. Yapılan analizlerde en yüksek başarımları EA (%84,58) ulaşılmıştır. Mamun vd. (2022) KY ile ilintili patofizyolojik parametrelerden hasta sağkalımını tahmin etmek için çeşitli MÖ sınıflandırıcıları için korelasyon matrisine göre en önemli risk faktörlerine karşılık gelen özelliklerin analizini araştırmışlardır. Yapılan analizler, LightGBM'nin %85 doğruluk ile diğer MÖ algoritmalarına kıyasla daha yüksek başarımları elde ettiğini tespit etmişlerdir. Muntasir Nishat vd. (2022) KY teşhisinde standart ve min-max ölçeklendirme yöntemlerini kullanarak farklı MÖ algoritmalarının performanslarını SMOTE ve düzenlenmiş en yakın komşu veriyi yeniden örnekleme tekniği (SMOTE-ENN) uygulanması durumları için araştırmışlardır. Yapılan analizler sonucunda; SMOTE-ENN ve standart ölçekleme tekniği ile birlikte kullanıldığında RO %90 test doğruluğu ile diğer tüm algoritmalarından daha yüksek performansa sahip olduğu ortaya koyulmuştur. Özbay ve Özbay (2022) tarafından yakın zamanda yapılan bir çalışmada 4 farklı performans ölçütüne dayanarak 10 farklı MÖ tekniğinin kalp yetmezliğine sahip hastaların hayatta kalma oranını tahminindeki başarımlarını araştırmışlardır. Yapılan çalışmada sınıflardaki dengesizliklerin üstesinden gelmek adına SMOTE yöntemi uygulanmış ve en başarılı MÖ al-

goritmasının RO olduğu tespit edilmiştir. 2022 yılında yapılan başka bir çalışmada ikili parçacık sürü optimizasyonu (BPSO) algoritmasıyla belirlenen öznelikler kullanılarak geliştirilen RO modeliyle %80 doğruluk oranıyla KY tanılı hastaların tahmin edilebileceği gösterilmiştir (Salman ve Aksoy 2022). Keser ve Keskin (2023) üç farklı MÖ tekniğinin (YSA, RO ve aşırı gradyan arttırma (AGA)) KY hastalarının sağkalım tahminindeki başarımlarını araştırdığı çalışmalarında, YSA'nın %86,67 ile en yüksek sınıflandırma performansına sahip olduğu tespit etmişlerdir. Yakın zamanda yapılan başka bir çalışmada KY'nin erken teşhisinde sekiz farklı MÖ tekniğinin başarımlarını araştırılmış ve en yüksek başarımların RO ile elde edildiği ortaya koyulmuştur (Gürgeç ve Serttaş, 2023).

Yukarıda bahsedilen çalışmalar KY hastalarının sağkalım tahmininde MÖ algoritmalarının oldukça etkili olduğunu göstermesine rağmen, bu tekniklerden en yüksek başarımları hangisine ait olduğu hususunda tartışmalar süre gitmektedir. Bu doğrultuda bu çalışmada KY sahip hastaların sağkalım oranlarının belirlenmesinde daha önceden önerilen ve yukarıda bahsedilen karar destek sistemlerinden esinlenerek etkili ve verimli bir MÖ temelli yapay zeka modeli önerilmiştir. Bu doğrultuda önerilen modelde farklı MÖ algoritmalarının başarımları irdelenmiştir. Çalışmada ilk olarak KY verileri ön işleme tabi tutulup, bozucu örneklerden temizlenerek yeni bir veri seti elde edilmiştir. Sonrasında da veri seti [0,1] arasında normalize edilerek, çapraz doğrulama teknikleri ile 8 farklı MÖ yönteminin eğitiminde kullanılmıştır. Eğitim süreci, hem tüm özellikleri hem de kümeleme temelli özellik seçimi algoritması yardımıyla elde edilen optimal özellikleri içeren veri setleri için gerçekleştirilmiştir. Ek olarak çalışma kapsamında optimal özellikleri içeren veri seti için SMOTE tekniğinin MÖ yöntemlerinin başarımlarına etkisi de araştırılmıştır.

Çalışmada, Bölüm 2'te veri seti, kullanılan MÖ algoritmaları ve performans metrikleri detaylandırılmıştır. Bölüm 3'te ise farklı çapraz doğrulama tekniklerine göre MÖ algoritmalarının performansları kıyaslanmıştır. Son bölümde ise çalışma literatürdeki ilgili çalışmalarla karşılaştırılmıştır.

## 2. Gereç ve Yöntemler

### 2.1. Veri Seti

Bu çalışmada, internet üzerinden açık erişime sahip UCI Machine Learning Repository veri tabanında yer alan "Heart Failure Clinical Records" başlıklı veri seti kullanılmıştır (UCI 2023). Veri seti, Nisan-Aralık 2015 tarihleri arasında Pakistan Faysalabad Kardiyoloji Enstitüsü ve Allied

Hastanesi'ne başvuran 299 kalp yetmezliği tanılı hastanın tıbbi kayıtlarını içermektedir. Hastaların 105'i kadın 194'ü erkek olup, yaşları 40 ila 95 (ortalama yaş 60,83) arasında değişmektedir. Bununla birlikte hastaların tamamında sol ventriküler sistolik fonksiyon bozukluğu mevcut olup, New York Kalp Cemiyeti'nin (NYHA) konjestif kalp yetmezliği sınıflamasına göre Sınıf III ve IV'de yer almaktadır (Ahmad vd. 2017).

Veri setinde hastaların yaşları, tütün kullanım durumu, çeşitli kan tahlili sonuçları ile diyabet, tansiyon ve anemi gibi hastalıklara sahip olup olmadıklarına dair bilgilere yer verilmiştir. Bunlardan kreatinin fosfokinaz (CPK), trombosit, ejeksiyon fraksiyonu, kreatinin ve sodyum değerleri sürekli (nümerik) değişkenler; sigara kullanımı, diyabet, anemi, kan basıncı (KB) ve cinsiyet ise kategorik değişkenler olarak tanımlanmıştır (Tablo 1). Bunların yanı sıra hastaların sağ kalım süreleri zaman olarak bilinen bir değişkenle gün cinsinden verilmiştir. Veri setinde eksik değer bulunmamakla birlikte; takip süresi boyunca (ortalama 130 gün) hastaların 96'sının hayatını kaybetmesi, veri setinin dengesiz bir dağılıma sahip olduğunu göstermektedir. Veri setinde ölüm=1 ölen hastayı, ölüm=0 ise hayatta kalan hastayı ifade etmektedir. Veri setinin genel özeti Çizelge 1'de sunulmuştur (Potur ve Erginel 2021, Gürgeç ve Serttaş 2023). Bu çalışma kapsamında bu değişkenleri kullanarak kalp yetmezliğine

sahip hastaların sağ kalımlarını gerçeğe en yakın olacak şekilde tespit edilmesi amaçlanmıştır.

## 2.2. Özellik Seçimi

Özellik seçimi, bir MÖ sürecinde kullanılan temel bir adım olup, modelin performansını veri setindeki özelliklerin seçimi veya elenmesi yoluyla artırmayı hedeflemektedir. Bu süreç, gereksiz veya gürültülü verilerin çıkartılarak modelin genelleme yeteneğini artırmakta ve aynı zamanda işlem maliyetini azaltmaktadır (Selvakuberan vd. 2008). Literatürde özellik seçimine yönelik birçok algoritma bulunmaktadır. Bunlardan CfsSubsetEval algoritması, özellikler arasındaki korelasyonu değerlendirerek en anlamlı bilgiyi taşıyan özelliklerin tespitine odaklanmaktadır. Bu algoritma genellikle en iyi ilk arama (Best First Search) veya genetik arama (Genetic Search) gibi bir arama algoritmasıyla birleştirildiğinde daha yüksek performans sergilemektedir (Bektaş ve Babur 2016). Arama algoritmaları, özellik alt kümelerini sistemli bir şekilde keşfetmek ve en iyi performansı sağlayacak özellikleri seçmek amacıyla kullanılmaktadır. Çalışma kapsamında, veri setindeki optimum özellikleri tespit etmek için CfsSubsetEval algoritması ile en iyi ilk arama yöntemi seçilmiştir. Bunun için WEKA programından faydalanılmış olup, veri setinde yer alan tüm özellikler arasından en etkili olanlar (yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre) tespit edilmiştir.

**Çizelge 1:** Veri setinde yer alan özelliklerinin tanımı, ölçüm birimleri ve aralıkları

Özellik	Tanımı	Ölçü Birimi	Aralığı
Yaş	Hasta yaşı	Yıl	[40 – 95]
Cinsiyet	Kadın veya Erkek	Binary (İkili)	0, 1
Tütün kullanımı	Hastanın sigara içme durumu	Binary (İkili)	0, 1
Anemi	Kırmızı kan hücrelerinde veya hemoglobinde azalma durumu	Binary (İkili)	0, 1
Yüksek kan basıncı	Hastada yüksek tansiyon olup olmaması durumu	Binary (İkili)	0, 1
Kreatinin Fosfokinaz (CPK)	CPK enziminin kandaki seviyesi	mcg/L	[23-7861]
Diyabet	Hastanın diyabet olma durumu	Binary (İkili)	0, 1
Ejeksiyon Fraksiyonu	Kalbin her kasılmasında çıkan kan yüzdesi	Yüzde	[14-80]
Trombositler	Kandaki trombosit miktarı	kilotrombosit/mL	[25.0150.00]
Serum Kreatinin	Kandaki kreatinin miktarı	mg/dL	[0.50- .40]
Serum Sodyum	Kandaki sodyum miktarı	mEq/L	[114-148]
Zaman	Hastalığın takip süresi	Gün	[4-285]
(Hedef) Ölüm Olayı	Hastanın takip süresi sonundaki sağ kalım bilgisi	Binary (İkili)	0, 1

## 2.3. Makine Öğrenme Algoritmaları

### 2.3.1 *K en yakın komşu (kNN)*

K en yakın komşu (KNN) algoritması, örnekleri uzayda noktalar olarak temsil edilen bir veri seti üzerinde sınıflandırma veya regresyon görevleri için kullanılan denetimli MÖ algoritmasıdır. Temel prensibi, bilinmeyen bir örneği sınıflandırmak veya tahmin etmek için en yakın komşularının etrafındaki etiketleri veya değerleri kullanmaya dayanmaktadır. Bu algoritma, veri noktalarının uzayda geometrik olarak birbirine yakın olan benzer özelliklere sahip veri noktalarının aynı sınıfa veya benzer bir değere sahip olma eğilimini temel almaktadır. KNN, genellikle eğitim verileri üzerinde basit bir uzaklık ölçümü (örneğin, Öklid mesafesi) kullanarak yeni örnekleri sınıflandırmakta veya tahmin etmektedir. K değeri komşuların sayısını belirtirken, algoritmanın performansını da etkilemektedir. Bu algoritma basit ve etkili olmasında rağmen, büyük veri setlerinde ve yüksek boyutlu veri uzaylarında hesaplama maliyetini artabilmektedir (Duda vd. 2000, Uzun vd. 2018, Azam vd. 2020, Turan 2023).

### 2.3.2 *Lojistik regresyon (LR)*

Lojistik regresyon (LR), istatistik ve MÖ alanlarında sıklıkla kullanılan bir diğer sınıflandırma algoritmasıdır. Temel mantığı bağımlı bir değişkenin (genellikle kategorik) belirli bağımsız değişkenlerle olan ilişkisinin modellenmesine dayanmaktadır. Bu algoritma, bağımlı değişkenin olasılığını tahmin etmek için kullanılmakta ve genellikle ikili sınıflandırma problemlerinde tercih edilmektedir. LR, basit yapısı ve yüksek uygulanabilirliği sayesinde hızlı eğitim ve tahmin sağlarken, doğrusal ayrılabilir olmayan veri setlerinde etkisiz olabilmekte ve karmaşık ilişkileri modelleme konusunda kısıtlı kalabilmektedir (Ishaq vd. 2021, Khan vd. 2023, Seven vd. 2023).

### 2.3.3 *Gaussian naive bayes (G-NB)*

Gaussian Naive Bayes (G-NB), Naive Bayes sınıflandırma algoritmasının bir türüdür. Temelinde Bayes Teoremi'ne dayanan bu algoritma, bir örneğin belirli bir sınıfa ait olma olasılığını hesaplamak için sınıf etiketinin ve özniteliklerin arasındaki olasılık ilişkilerini kullanmaktadır. Bu algoritma, sınıflandırma sürecinde her özelliğin normal (Gaussian) bir dağılıma sahip olduğunu varsaymaktadır. Algoritmada sınıflandırma sürecinde, Bayes Teoremi kullanılarak belirli bir sınıfa ait olasılık hesaplamak ve en yüksek olasılığa sahip sınıf tahmin edilen sınıf olarak seçilmektedir. G-NB hızlı ve basit olmasıyla öne çıkarken, özellikler arasındaki ger-

çek bağımlılıkları göz ardı ederek bağımsızlık varsayımına dayandığı için bazı durumlarda performansı düşük kalabilmektedir (Beltozar-Clemente vd. 2024).

### 2.3.4 *Karar ağacı (KA)*

Karar Ağacı (KA) algoritması, veri setindeki desenleri hiyerarşik bir yapı içinde temsil eden bir modelleme tekniğidir. Temel prensibi, veri kümesindeki öznitelikleri kullanarak bir dizi kararlar kuralı oluşturmaya dayanmaktadır. Daha sonra bu kurallara dayalı olarak verinin sınıflandırma veya regresyon işlemini gerçekleştirmektedir. KA, genellikle anlaşılabilirlikleri ve yorumlanabilirlikleri nedeniyle tercih edilmektedirler. Ancak, algoritmanın tek başına kullanımı verilerdeki karmaşık ilişkileri ifade etmekte bazen kısıtlı kalabilmekte ve bu nedenle aşırı uyum riski taşıyabilmektedir (Charbuty ve Abdulazeez 2021).

### 2.3.5 *Rastgele orman (RO)*

Rastgele Orman (RO) karar ağaçlarının birleştirilmesiyle oluşturulan bir topluluk (ensemble) öğrenme algoritmasıdır. Algoritmada her bir karar ağacı, rastgele seçilmiş alt öznitelikler üzerinde eğitilmekte ve bu ağaçlar arasında yapılan oylama (ortalamalarının alınması) ile sınıflandırma (regresyon) işlemi gerçekleştirilmektedir. Algoritmanın temel avantajları, aşırı uydurmayı (overfitting) azaltma, yüksek boyutlu veri setlerinde etkili performans sergileme ve öznitelik önem sıralamalarını sağlama yeteneklerine sahip olmasıdır. Ayrıca, paralel işlem yetenekleri sayesinde büyük veri setlerinde etkili bir şekilde çalışabilmektedirler (Pandimurugan vd. 2022, Atasoy ve Kara 2023, Cesur ve Cemal 2023).

### 2.3.6 *Gradyan arttırma (GB)*

Gradyan arttırma (Gradient Boosting, GB), zayıf öğreniciler adı verilen basit modellerin (genellikle karar ağaçları) bir araya getirilmesiyle daha güçlü bir tahmin modelini oluşturan önemli bir topluluk öğrenme algoritmasıdır. Bu algoritma, hata fonksiyonunu minimize etmek amacıyla önceki modellerin hatalarına odaklanan iteratif bir süreci takip etmektedir. Bu iteratif süreç, öğrenme oranı ve ağaç derinliği gibi hiperparametrelerle yönetilmektedir. Genellikle KA temel alınarak regresyon ve sınıflandırma problemlerinde etkili sonuçlar elde edilmektedir. GB'nin en önemli avantajları yüksek tahmin performansı ve karmaşık ilişkileri modelleme yeteneklerine sahip olmasıdır. Dezavantajları ise eğitim sürecinin hesaplama açısından yoğun olması ve hiperparametre ayarının önemli olmasıdır (Friedman 2002, Natekin ve Knoll 2013, Sarıkaya 2020, Nusrat vd. 2020, Bentéjac vd. 2021).

### 2.3.7 Ekstrem Gradyan Arttırma (GB)

Ekstrem Gradyan Arttırma (Extreme Gradient Boosting, XGBoost), GB 'nin optimize edilmiş ve performansı artırılmış versiyonudur. Daha verimli hesaplama yöntemleri kullanarak eğitim sürecini hızlandıran XGBoost, paralel hesaplama yetenekleri sayesinde özellikle büyük veri setlerinde daha yüksek başarımlar sergilemektedir. Ayrıca, aşırı öğrenmeye karşı dirençli olmak için çeşitli düzenleme teknikleri ve hiperparametrelerin otomatik ayarlanmasını sağlayan özellikler içermesi algoritmaya daha esnek bir kullanım olanağı sağlamaktadır (Maulana vd. 2023, Yılmaz ve Bakır 2023).

### 2.4. Çapraz Doğrulama Yöntemleri

MÖ'de çapraz doğrulama teknikleri, modelin genelleme yeteneğini ve performansını daha güvenilir bir şekilde değerlendirmek için kullanılmaktadır. Bu bağlamda gerçekleştirilen çalışmada modellerin başarımları, literatürde yaygın olarak kullanılan k-katlamalı (k-fold) ve birisi dışarıda (leave-one-out- LOO) çapraz doğrulama tekniklerine dayanarak değerlendirilmiştir (James vd. 2013).

#### 2.4.1.k-katlamalı (k-kat) çapraz doğrulama yöntemi

Bu yöntem, veri setini rasgele k eşit parçaya bölmekte ve her parçayı sırayla test seti olarak kullanarak modeli k defa eğiterek değerlendirmektedir. Her iterasyonda farklı bir parça test seti olarak seçilmekte ve geri kalanlar eğitim verisi olarak kullanılmaktadır. Bu şekilde k defa yapılan bu işlemlerin ortalaması alınarak modelin genel performans ölçüsü elde edilmektedir. Bu çalışmada k değeri 10 olarak seçilmiştir (Wong ve Yeh 2020).

#### 2.4.2.Birisi dışarıda çapraz doğrulama yöntemi (LOO)

Birisi dışarıda çapraz doğrulama (leave-one-out, LOO) yöntemi, veri setindeki her bir örneği sırasıyla dışarıda bırakarak modeli eğitip test etme sürecini ifade etmektedir. Bu yöntemde her iterasyonda bir örnek test için kullanılmakta ve geri kalan veri setiyle de model eğitilmektedir. Bu işlem, veri setindeki her örneği test etmek için tekrarlanmaktadır. Bu durum modelin genelleme yeteneği hakkında daha güvenilir bir değerlendirme yapılmasına olanak sağlamaktadır. Buna karşın, büyük veri setleri için yüksek hesaplama maliyetleri nedeniyle kullanışlı olmamaktadır (Narin vd. 2014, Wong 2015).

#### 2.4.3 Sentetik azınlık aşırı örnekleme tekniği (SMOTE)

Sentetik Azınlık Aşırı Örnekleme Tekniği (sentetic minority over-sampling technique, SMOTE), sınıf dengesizliği

içeren veri setlerinde azınlık sınıfını güçlendirmek ve modelin performansını artırmak amacıyla kullanılan bir örnekleme yöntemidir. Bu teknik, azınlık sınıfındaki örnekleri analiz etmekte ve her bir azınlık örneğinin komşularını dikkate alarak yeni sentetik örnekler oluşturmaktadır. Bu sentetik örnekler, azınlık sınıfının veri boşluğunu doldurmak ve dengesizliği azaltmak için kullanılmaktadır. SMOTE, az sayıda örneği olan sınıfların neden olduğu dengesizlik sorunlarını çözmek ve sınıflandırma performansını artırmak için kullanılmaktadır (Chawla 2010, Blagus ve Lusa 2015). Bu çalışmada, SMOTE tekniği kullanılarak yeni eğitim veri seti oluşturulmuştur. Böylelikle SMOTE ile veri örneklerini her sınıf için 299 örnekten 406 örneğe çıkarılmıştır.

### 2.5. Performans Metrikleri

Sınıflandırıcıların performansı, gerçek etiketlerle yapılan karşılaştırmalar ve tahminler arasındaki uyumu değerlendiren metriklerle ölçülmektedir. Bu bağlamda doğruluk (accuracy, ACC), kesinlik (precision, Prec), özgüllük (specificity, Spec) ve F-ölçütü gibi metrikler kullanılmaktadır. Bu metrikler sınıflandırıcıların doğruluğunu, yanlılığını, tam hatırlama yeteneğini ve doğru pozitiflerle yanlış pozitifler arasındaki dengeyi belirlemektedir. Yapılan çalışma kapsamında sınıflandırıcıların performansları doğruluk (ACC), kesinlik, özgüllük ve F-ölçütü metriklerine göre değerlendirilmiştir. İlgili metriklere ait denklemler aşağıda verilmiştir.

$$\text{Doğruluk (ACC)} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

$$\text{Kesinlik (Prec)} = \frac{DP}{DP + YP} \quad (2)$$

$$\text{Özgüllük (Spec)} = \frac{DN}{DN + YP} \quad (3)$$

$$F - \text{Ölçütü} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Burada DP (Doğru Pozitif) sınıflandırıcının doğru bir şekilde pozitif tahmin ettiği örnekleri, DN (Doğru Negatif) gerçekten negatif olan örnekleri, YP (Yanlış Pozitif) gerçekte negatif olan örnekleri yanlış pozitif tahmin ettiği durumları ve YN (Yanlış Negatif) gerçekte pozitif olan örnekleri yanlış negatif tahmin ettiği durumları ifade etmektedir.

### 3. Bulgular ve Tartışma

Bu çalışmada, kalp yetmezliği tanılı hastaların sağ kalım veya ölüm durumlarının tahmin edilmesi için farklı MÖ algoritmalarının performansları analiz edilmiştir. Çalışmada öncelikle MÖ algoritmalarının başarımlarını arttırmak amacıyla veri setindeki en anlamlı özellikler tespit edilmiştir. Bunun

için WEKA programında yer alan CfsSubsetEval özellik seçim yöntemi ile en iyi ilk arama (Best fit) algoritmasından faydalanılmıştır. Yapılan benzetim çalışmaları sonucunda veri setinde en anlamlı özellikler yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre olarak belirlenmiştir. Sonrasında, bu beş özellik kullanılarak 7 farklı MÖ algoritmasının performansları 10-kat çapraz doğrulama ve birini dışarıda bırak çapraz doğrulama (LOO) teknikleriyle elde edilen analizlerin sonuçları karşılaştırılmıştır. Analizler Phyton programı kullanılarak gerçekleştirilmiştir. MÖ algoritmalarının seçimi literatürde kalp yetmezliği tanılı hastaların sağ kalımının tahmini üzerine yapılan çalışmalar baz alınarak yapılmıştır. Bu bağlamda K-en yakın komşu (KNN), Gauss Naive Bayes (G-NB), Karar ağacı (KA), Rasgele orman (RO), Extreme Gradient Boosting (XGBoost), Lojistik regresyon (LR) ve Gradient Boosting (GB) algoritmalarından faydalanılmıştır. Bunun yanı sıra veri setindeki dengesizlik probleminin önüne geçebilmek için SMOTE

tabanlı örnekleme yöntemi kullanılmıştır. SMOTE'nin olduğu ve olmadığı durumlardaki MÖ algoritmalarının performansları ayrı ayrı analiz edilmiştir. Elde edilen sonuçlar sırasıyla Çizelge 2 ve Çizelge 3' de verilmiştir.

Çizelge 2'de yer alan sonuçlar irdelendiğinde; 10 kat çapraz doğrulama tekniğinin kullanılması durumunda MÖ algoritmaları arasından sınıflandırma başarımı en yüksek KA ve XGBoost iken, en düşük olan ise G-NB'dir. KA algoritmasının doğruluk, duyarlılık, kesinlik ve f-ölçütü metrikleri sırasıyla %83, %94, %90 ve %78'dir. XGBoost algoritmasının doğruluğu %83, özgüllüğü %88, kesinliği %83 ve f-ölçütü %80'dir. G-NB algoritması için elde edilen başarımler metriklerinden doğruluk %76, özgüllük ve kesinlik %100 iken f-ölçütü ise %63'dür. LOO tekniğinde ise en yüksek sınıflandırma başarımı KNN, RO ve G-NB algoritmalarından elde edilmiştir. En düşük sınıflandırma başarımı ise KA algoritmasında gözlemlenmiştir. KNN algoritmasının doğru-

**Çizelge 2.** Farklı makine öğrenme algoritmalarının 10-kat ve LOO çapraz doğrulama teknikleri için elde edilen başarımler metrikleri.

	10-kat				LOO			
	ACC (%)	Spec (%)	Prec (%)	F-Ölçütü (%)	ACC (%)	Spec (%)	Prec (%)	F-Ölçütü (%)
<b>KNN(k=3)</b>	79	94	89	73	85	84	63	73
<b>G-NB</b>	76	100	100	63	79	80	51	61
<b>KA</b>	83	94	90	78	77	82	59	63
<b>RO</b>	79	88	82	75	85	88	75	76
<b>XGBoost</b>	83	88	83	80	84	87	73	74
<b>LR</b>	79	94	89	73	82	85	67	71
<b>GB</b>	79	88	75	90	85	89	77	77

**Çizelge 3.** SMOTE örnekleme tekniği kullanılması durumunda farklı makine öğrenme algoritmalarının 10-kat ve LOO çapraz doğrulama teknikleri için elde edilen başarımler metrikleri.

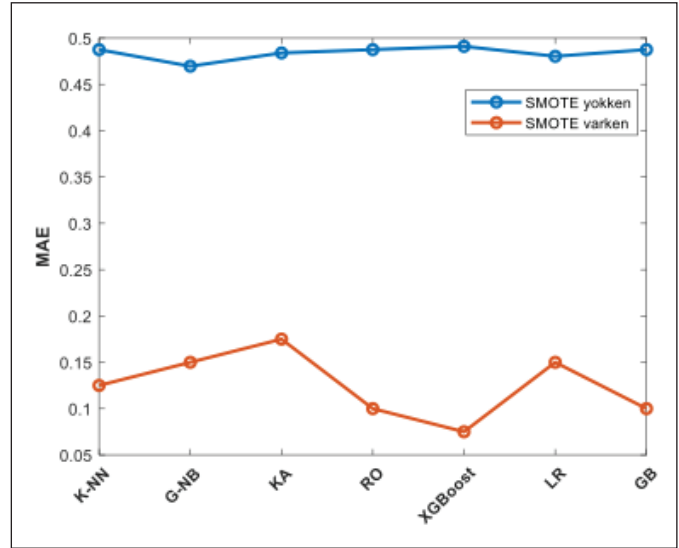
	10-kat				LOO			
	ACC (%)	Spec (%)	Prec (%)	F-Ölçütü (%)	ACC (%)	Spec (%)	Prec (%)	F-Ölçütü (%)
<b>KNN (k=3)</b>	83	89	89	83	84	82	80	84
<b>G-NB</b>	85	94	94	85	80	76	73	79
<b>KA</b>	83	94	94	82	85	83	83	85
<b>RO</b>	90	89	91	91	90	93	93	90
<b>XGBoost</b>	93	89	91	93	88	89	89	88
<b>LR</b>	85	89	90	86	81	80	80	81
<b>GB</b>	90	94	95	90	89	91	91	89

luğu %85, özgüllüğü %84, kesinliği %63 ve f-ölçütü %73'dür. RO algoritmasının doğruluk, özgüllük, kesinlik ve f-ölçütü değerleri sırasıyla %85, %88, %75 ve %75'dir. G-NB algoritmasının ise doğruluğu %85, özgüllüğü %89 iken kesinliği ve f-ölçütü %77'dir. KA algoritmasıyla en düşük sınıflandırma başarımı elde edilmiş olup, bu değer %77'dir. Diğer metrikler olan özgüllük, kesinlik ve f-ölçütü ise sırasıyla %82, %59 ve son olarak %63'dür.

Çizelge 3'de görüldüğü üzere LOO tekniği kullanılması durumunda en yüksek sınıflandırma doğruluğu %90 ile RO sınıflandırıcısından elde edilmiştir. RO sınıflandırıcısının özgüllük ve kesinlik değerleri %93 iken F-ölçütü ise %90'dır. G-NB sınıflandırıcısı ise en düşük sınıflandırma başarımını vermiş olup, sınıflandırma başarımı %80'dir. Sınıflandırıcının özgüllük, kesinlik ve F-ölçütü değerleri sırasıyla %76, %73 ve %79'dur. Çapraz doğrulama yöntemi olarak 10-kat çapraz doğrulama kullanılması durumunda en yüksek sınıflandırma başarımı %93 ile XGBoost sınıflandırıcısından, en düşük sınıflandırma başarımı ise %83 ile KNN ve KA sınıflandırıcılarından elde edilmiştir. KNN sınıflandırıcısının özgüllüğü ve kesinliği %89, F-ölçütü %83 olarak hesaplanmıştır. KA sınıflandırıcısında ise özgüllük ve kesinlik %94 iken F-ölçütü %82'dir. Son olarak XGBoost sınıflandırıcısının özgüllük, kesinlik ve F-ölçütü metriklerinin değeri sırasıyla %89, %91 ve %93 olarak elde edilmiştir.

Elde edilen tüm sonuçlar göz önüne alındığında kalp yetmezliği bulunan bireylerin sağ kalım veya ölüm durumlarının tahmininde SMOTE tabanlı örnekleme yönteminin eklenmesi sınıflandırıcıların başarımını arttırdığı görülmektedir. Yanı sıra SMOTE yönteminde 10- kat çapraz doğrulama tekniğinin kullanılması durumunda en yüksek sınıflandırma başarımı elde edilmektedir. Sınıflandırıcılar arasında en yüksek doğruluk değeri XGBoost algoritmasının 10-kat çapraz doğrulama yöntemiyle kullanılması durumunda elde edildiği görülmektedir. Bu bağlamda 10-kat çapraz doğrulama yöntemi için SMOTE yönteminin olduğu ve olmadığı durumlarda her bir sınıflandırma algoritması için elde edilen ortalama mutlak hata (MAE) değerleri Şekil 1 ve Çizelge 4'de verilmiştir.

Şekil 1'de görüldüğü üzere SMOTE yönteminin eklenmesi durumunda hata değerleri düşmektedir. SMOTE yönteminin olmaması durumunda en yüksek hata değeri XGBoost algoritmasında ve en düşük hata değeri G-NB algoritmasında elde edilmiştir. SMOTE yönteminin eklenmesi durumunda ise en yüksek ve en düşük hata değerleri sırasıyla KA ve XGBoost algoritmalarında gözlenmiştir.



Şekil 1. SMOTE tekniğinin uygulanıp uygulanmaması durumları için yedi farklı makine öğrenme algoritmasında hatanın değişimi.

Çizelge 4. SMOTE tekniğinin uygulanıp uygulanmaması durumları için yedi farklı makine öğrenme algoritmasında elde edilen ortalama mutlak hata değerleri.

	Mutlak hata değerleri	
	SMOTE uygulanmaması durumu	SMOTE uygulanması durumu
<b>KNN (k=3)</b>	0.4875	0.1250
<b>G-NB</b>	0.4696	0.1500
<b>KA</b>	0.4839	0.1750
<b>RO</b>	0.4875	0.1000
<b>XGBoost</b>	0.4910	0.0750
<b>LR</b>	0.4803	0.1500
<b>GB</b>	0.4875	0.1000

Çalışmada son olarak kalp yetmezliği tanılı hastaların sağ kalımlarının tahmininde MÖ algoritmalarının başarımları literatürde aynı veri seti kullanılarak yapılan diğer çalışmalarla karşılaştırılmıştır (Çizelge 5). Bu karşılaştırmada, veri seti ayırımı ve özellik seçimi sürecinin nasıl yapıldığı hususunda detay verilmemiş çalışmalar göz ardı edilmiştir. Çizelge 5'den de açıkça görüldüğü üzere önerilen çalışma literatürde yer alan diğer çalışmalar arasında öne çıkmaktadır. SMOTE tekniğinin uygulanması sınıflandırıcılarının performansları artırmıştır.



**Çizelge 5.** Kalp yetmezliği veri seti ile yapılan çalışmaların karşılaştırılması.

Yazarlar	Kullanılan Yöntem(ler)	Özellik Sayısı	ACC (%)
Chicco ve Jurman (2020)	RO	2	75.4
Rahayu vd. (2020)	DVM	12	83
Erdaş ve Ölçer, (2020)	Bir Kural (One rule)	12	86
Ishaq vd. (2021)	SMOTE+ Ekstra Ağaç (EA)	8	92.62
Potur ve Erginel (2021)	Çok katmanlı algılayıcı	4	90
Türkmenoğlu ve Yıldız, (2021)	Aşağı Örnekleme+ EA	3	84.58
Gürfidan ve Ersoy (2021)	DVM	12	83
Salman ve Aksoy (2022 )	RO+hiper parametre ayarı +BPSO	7	80
Özbay ve Özbay (2022)	SMOTE+RO	12	87.088
Keser ve Keskin (2023)	YSA	12	86.67
<b>Bu Çalışma</b>	<b>KNN, G-NB, RO</b>	<b>5</b>	<b>85</b>
<b>Bu Çalışma</b>	<b>SMOTE +XGBoost</b>	<b>5</b>	<b>93</b>

#### 4. Sonuç ve Öneriler

Kalp yetmezliği sinsi seyirle ilerleyen ve hayati riskler içeren bir sağlık sorunu olup, erken teşhisi önem arz etmektedir. Bu bağlamda son yıllarda uzman hekimlerin karar verme sürecine destek sağlamak amacıyla bilgisayar tabanlı karar destek sistemleri geliştirilmektedir. Karar destek sistemlerinin uzman hekimlere sundukları önerilerle hatalı kararların önüne geçilmekte ve erken teşhis aşamasına ciddi katkılar sağlamaktadır. Kalp yetmezliğine katkıda bulunan faktörler analiz edilip, önleyici tedbirler alınarak ölüm oranı kontrol altına alınabilmektedir. Bu çalışmada, kalp hastalarının hayatta kalma tahmini için etkili ve verimli bir makine öğrenmesi temelli bir yapay zeka modeli tasarlanmaya çalışılmıştır. Bu amaç doğrultusunda KNN, G-NB, KA, RO, LR, XGBoost ve GB algoritmaları kullanılmıştır. Veri seti kaynaklı bozucu etkileri minimize etmek ve örnek setini arttırmak amacıyla SMOTE uygulanmıştır. Yanı sıra, veri homojenliğini sağlamak ve tüm örnekleri hem test hem de eğitim süreçlerinde kullanarak daha gerçekçi doğruluk değerine sahip modeller elde etmek için çapraz doğrulama tekniğinden yararlanılmıştır. Ek olarak, CfsSubsetEval öznelik seçim yönteminin en iyi ilk arama algoritması kullanılmıştır. En iyi ilk arama algoritmasına göre en önemli özellikler yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre olarak tespit edilmiştir. Daha sonra veri setinden seçilen bu özellikler kullanılarak makine öğrenme algoritmalarının performansları karşılaştırılmıştır.

#### 5. Kaynaklar

- Ahmad, T., Munir, A., Bhatti, SH., Aftab, M., ... Raza, MA. 2017. Survival analysis of heart failure patients: A case study. PloS one, 12(7): e0181001. Doi: 10.1371/journal.pone.0181001.
- Ali, L., Khan, S. U., Golilarz, N. A., Yakubu, I., Qasim, I., Noor, A., Nour, R. 2019. A feature-driven decision support system for heart failure prediction based on statistical model and Gaussian Naive Bayes. Computational and Mathematical Methods in Medicine, 2019: 6314328-8. Doi: 10.1155/2019/6314328.
- Atasoy, D., Kara, H. 2023. Karar ağacı optimizasyon algoritması üzerine bir çalışma. Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 13(2): 1247-1255. Doi: 10.21597/jist.1214796.
- Azam, MS., Rahman, A., Iqbal, SHS., Ahmed, MT. (2020). Prediction of liver diseases by using few machine learning based approaches. Aust. J. Eng. Innov. Technol, 2(5): 85-90.
- Bektaş, B., Babur, S. 2016. Makine öğrenmesi teknikleri kullanılarak meme kanseri teşhisinin performans değerlendirilmesi, TıpTekno»16 Tıp Teknolojileri Kongresi, s.1-4, Türkiye.
- Beltzar-Clemente, S., Diaz-Vega, E., Ramos, IC., Navarrete, RT. 2024. Improving accuracy: Comparative analysis of machine learning models for prostate cancer prediction. International Journal of Intelligent Systems and Applications in Engineering, 12(2): 654-664.
- Bentéjac, C., Csörgő, A., Martínez-Muñoz, G. 2021. A comparative analysis of gradient boosting algorithms. Artif. Intell. Rev., 54:1937-1967. Doi: 10.1007/s10462-020-09896-5.

- Blagus, R., Lusa, L. 2015.** Joint use of over-and under-sampling techniques and cross-validation for the development and assessment of prediction models. *BMC bioinformatics*, 16(1): 1-10. Doi: 10.1186/s12859-015-0784-9.
- Cesur, E., Cemal, E. 2023.** Kampüs içi kapalı alanlarda hava kalitesinin modellenmesi ve karar destek sistemi geliştirilmesi. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 6(2): 181-190. Doi: 10.38016/jista.1222483.
- Charbuty, B., Abdulazeez, A. 2021.** Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01): 20-28. Doi: 10.38094/jastt20165.
- Chawla, NV. 2010.** Data mining for imbalanced datasets: An overview. In: Maimon, O., Rokach, L. (eds). *Data mining and knowledge discovery handbook*, Springer, Boston, MA pp. 853-867.
- Chiarugi, F., Colantonio, S., Emmanouilidou, D., Moroni, D., Salvetti, O. 2008.** Biomedical signal and image processing for decision support in heart failure. In *Advances in Mass Data Analysis of Images and Signals in Medicine, Biotechnology, Chemistry, and Food Industry. Proceeding of the Third International Conference, Leipzig, Germany, (Lecture Notes in Computer Science)*, Ed. by P. Perner and O. Salvetti (Springer, 2008), Vol. 5108, pp. 38-51.
- Chicco, D., Jurman, G. 2020.** Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone. *BMC Medical Informatics and Decision Making*, 20(1):1-16. Doi: 10.1186/s12911-020-1023-5.
- Çilhoroz, İA., Çilhoroz, Y. 2021.** Kardiyovasküler hastalıklara bağlı ölümleri etkileyen faktörlerin belirlenmesi: OECD ülkeleri üzerinde bir araştırma. *Acıbadem Sağlık Bilimleri Dergisi*, 12(2):340-345. Doi: 10.31067/acusaglik.849024
- Erdas, CB., Olcer, D. 2020.** *A machine learningbased approach to detect survival of heart failure patients.* 2020 Medical Technologies Congress, pp. 1-4, Antalya, Turkey.
- Friedman, JH. 2002.** Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4): 367-378. Doi: 10.1016/S0167-9473(01)00065-2.
- Gürfidan, R., Ersoy, M. 2021.** Classification of death related to heart failure by machine learning algorithms. *Advances in Artificial Intelligence Research*, 1(1): 13-18.
- Gürgen, G., Serttaş, S. 2023.** Kalp yetmezliği hastalığının erken teşhisinde makine öğrenimi algoritmalarının performans karşılaştırması. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 10(28):165-174. Doi: 10.5281/zenodo.8238065.
- Hart, PE., Stork, DG., Duda, RO. 2000.** *Pattern classification.* Hoboken: Wiley, NJ, USA.
- Ishaq, A., Sadiq, S., Umer, M., Ullah, S., Mirjalili, S., Rupapara, V., Nappi, M. 2021.** Improving the prediction of heart failure patients' survival using SMOTE and effective data mining techniques. *IEEE access*, 9, 39707-39716.
- James, G., Witten, D., Hastie, T., Tibshirani, R. 2013.** *An Introduction to Statistical Learning.* New York, Springer.
- Keser, SB., Keskin, K. 2023.** Kalp yetmezliği hastalarının sağ kalım tahmini: Sınıflandırmaya dayalı makine öğrenmesi algoritmalarının bir uygulaması. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 23(2), 362-369.
- Khan, RA., Rashid, N., Shahzaib, M., Malik, UF., Arif, A., Iqbal, J., ... Tiwana, M. 2023.** A novel framework for classification of two-class motor imagery EEG signals using logistic regression classification algorithm. *Plos one*, 18(9), e0276133.
- Küçükakçalı, Z., Çiçek, I., Güldoğan, E., Çolak, C. 2020.** Assessment of associative classification approach for predicting mortality by heart failure. *The Journal of Cognitive Systems*, 5(2):41-45.
- Maulana, A., Faisal, FR., Noviandy, TR., Rizkia, T., Idroes, GM., Tallei, TE., ... Idroes, R. 2023.** Machine learning approach for diabetes detection using fine-tuned XGBoost algorithm. *Infolitika Journal of Data Science*, 1(1):1-7. Doi: 10.60084/ijds.v1i1.72.
- Mamun, M., Farjana, A., Al Mamun, M., Ahammed, MS., Rahman, MM. 2022.** Heart failure survival prediction using machine learning algorithm: am I safe from heart failure?. 2022 IEEE World AI IoT Congress, pp. 194-200.
- Mansur Huang, N. S., Ibrahim, Z., Mat Diah, N. 2021.** Machine learning techniques for early heart failure prediction. *Malaysian Journal of Computing (MJOC)*, 6(2), 872-884.
- Meng, F., Zhang, Z., Hou, X., Qian, Z., Wang, Y., Chen, Y., ... Zou, J. (2019).** Machine learning for prediction of sudden cardiac death in heart failure patients with low left ventricular ejection fraction: study protocol for a retrospective multicentre registry in China. *BMJ open*, 9(5), e023724.
- Muntasir Nishat, M., Faisal, F., Jahan Ratul, I., Al-Monsur, A., Ar-Rafi, AM., Nasrullah, SM., ... Khan, MRH. 2022.** A comprehensive investigation of the performances of different machine learning classifiers with SMOTE-ENN oversampling technique and hyperparameter optimization for imbalanced heart failure dataset. *Scientific Programming*, 2022:1-17. Doi: 10.1155/2022/3649406
- Narin, A., İşler, Y., Özer, M. 2014.** Konjestif kalp yetmezliği teşhisinde kullanılan çapraz doğrulama yöntemlerinin sınıflandırıcı performanslarının belirlenmesine olan etkilerinin karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48): 1-8.
- Natekin, A., Knoll, A. 2013.** Gradient boosting machines, a tutorial. *Frontiers in neurobotics*, 7: 21. Doi: 10.3389/fnbot.2013.00021.

- Nusrat, F., Uzbay, B., Baykan, ÖK. 2020.** Prediction of diabetes mellitus by using gradient boosting classification. *European Journal of Science and Technology*, 268-272. Doi: 10.31590/ejosat.803504
- Oladimeji, OO., Oladimeji, O. 2020.** Predicting survival of heart failure patients using classification algorithms. *Journal of Information Technology and Computer Engineering*, 4(2): 90-94. Doi: 10.25077/jitce.4.02.90-94.2020.
- Özby, FA., Özby, E. 2022.** Makine öğrenmesi algoritmalarının kalp yetmezliği hastalarının hayatta kalma tahmini üzerindeki performans karşılaştırılması, 2. International Mediterranean Scientific Research and Innovation Congress, pp. 503-515, Girne, KKTC.
- Pandimurugan, V., Usha, D., Guptha, MN., Hema, MS. 2022.** Random forest tree classification algorithm for predicating loan. *Materials Today: Proceedings*, 57 (2022), 2216-2222. Doi: 10.1016/j.matpr.2021.12.322.
- Potur, EA., Erginel, N. 2021.** Kalp yetmezliği hastalarının sağ kalımlarının sınıflandırma algoritmaları ile tahmin edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (24): 112-118. Doi: 10.31590/ejosat.902357
- Rahayu, S., Purnama, JJ., Pohan, A. B., Nugraha, FS., Nurdiani, S., Hadianti, S. 2020.** Prediction of survival of heart failure patients using random forest. *Jurnal Pilar Nusa Mandiri*, 16(2): 255-260.
- Salman OKM., Aksoy B. 2022.** Rasgele orman ve ikili parçacık sürü zekâsı yöntemiyle kalp yetmezliği hastalığındaki ölüm riskinin tahminlenmesi. *Uluslararası 3B Yazıcı Teknolojileri ve Dijital Endüstri Dergisi*, 6(3): 416-428.
- Sarıkaya, BS. 2020.** AES algoritmasına yapılan zaman odaklı önbellek saldırılarının makine öğrenmesi ile tespiti. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 13(1): 57-68.
- Saqlain, M., Hussain, W., Saqib, NA., Khan, MA. 2016.** *Identification of heart failure by using unstructured data of cardiac patients*. 45th International Conference on Parallel Processing Workshops (ICPPW), pp. 426-431, Philadelphia, PA, USA.
- Selvakuberan, K., Indradevi, M., Rajaram, R. 2008.** Combined feature selection and classification—a novel approach for the categorization of web pages. *Journal of Information and Computing Science*, 3(2): 083-089.
- Seven, S., Aydın, T., Karaman, G. 2023.** Öğrenci bilgi seviyesinin veri madenciliği yöntemleri ile belirlenmesi ve tahmin edilmesi. *Cognitive Models and Artificial Intelligence Conference*, s.36, Türkiye. Doi: doi.org/10.36287/setsoci.6.1.016.
- Shamsham, F., Mitchell, J. 2000.** Essentials of the diagnosis of heart failure. *American family physician*, 61(5), 1319-1328.
- Solanki, Y., Sharma, S. 2019.** A survey on risk assessments of heart attack using data mining approaches. *International Journal of Information Engineering and Electronic Business*, 11(4):43-51. Doi: 10.5815/ijieeb.2019.04.05.
- Takçı, H. 2023.** Performance-enhanced KNN algorithm-based heart disease prediction with the help of optimum parameters. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(1):451-460. Doi: 10.17341/gazimmfd.977127.
- TKD 2023.** <https://tkd.org.tr/menu/112/kalp-yetersizligi-farkindalik-gunu>
- Tripoliti, EE., Papadopoulos, TG., Karanasiou, GS., Naka, KK., Fotiadis, DI. 2017.** Heart failure: diagnosis, severity estimation and prediction of adverse events through machine learning techniques. *Computational and structural biotechnology journal*, 15, 26-47. Doi: 10.1016/j.csbj.2016.11.001.
- Turan, T. 2023.** Optimize edilmiş denetimli öğrenme algoritmaları ile obezite analizi ve tahmini. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(2) : 301-312.
- Türkmenoğlu, BK., Yıldız, O. 2021.** *Predicting the survival of heart failure patients in unbalanced data sets*. 29th Signal Processing and Communications Applications Conference, pp. 1-4, Istanbul, Turkey.
- UCI, 2023.** <https://archive.ics.uci.edu/dataset/519/heart+failure+clinical+records>
- Uzun, R., Isler, Y., Toksan, M. 2018.** *Use of support vector machines to predict the success of wart treatment methods*. 2018 Innovations in Intelligent Systems and Applications Conference (ASYU), pp. 1-4, Turkey.
- Wang, J. 2021.** Heart failure prediction with machine learning: a comparative study. In *Journal of Physics: Conference Series*, 2031:p. 012068, IOP Publishing: London, UK.
- WHO 2023.** [https://www.who.int/health-topics/cardiovascular-diseases#tab=tab\\_1](https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1)
- Wong, TT. 2015.** Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern recognition*, 48(9):2839-2846.
- Wong, TT., Yeh, PY. 2020.** Reliable accuracy estimates from k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8):1586-1594.
- Yancy, CW., Jessup, M., Bozkurt, B., Butler, J., Casey, DE., Drazner, MH., ... Wilkoff, BL. 2013.** 2013 ACCF/AHA guideline for the management of heart failure: a report of the American College of Cardiology Foundation/American Heart Association Task Force on Practice Guidelines. *Journal of the American college of cardiology*, 62(16): e147-e239
- Yılmaz, EK., Bakır, H. 2023.** Hyperparameter Tuning and Feature Selection Methods for Malware Detection. *Journal of Polytechnic*, 1-1. Doi: 10.2339/politeknik.1243881.