

T.C.  
YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ TEKNİKLERİNİ  
KULLANARAK KALP HASTALIĞI TAHMİNLERİ

Mina KARAÇAY

YÜKSEK LİSANS TEZİ  
Matematik Anabilim Dalı  
Matematik Programı

Danışman  
Doç. Dr. Mutlu AKAR

Ocak, 2025

**T.C.**  
**YILDIZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENİMİ TEKNİKLERİNİ KULLANARAK**  
**KALP HASTALIĞI TAHMİNLERİ**

Mina KARAÇAY tarafından hazırlanan tez çalışması 17.01.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Matematik Anabilim Dalı Matematik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Mutlu AKAR  
Yıldız Teknik Üniversitesi  
Danışman

**Jüri Üyeleri**

Doç. Dr. Mutlu AKAR, Danışman  
Yıldız Teknik Üniversitesi

\_\_\_\_\_

Doç. Dr. Muttalip ÖZAVŞAR, Üye  
Yıldız Teknik Üniversitesi

\_\_\_\_\_

Dr. Öğr. Üyesi Fatih TEMİZ, Üye  
Üsküdar Üniversitesi

\_\_\_\_\_

Danışmanım Doç. Dr. Mutlu AKAR sorumluluğunda tarafımca hazırlanan "Makine Öğrenimi Tekniklerini Kullanarak Kalp Hastalığı Tahminleri" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Mina KARAÇAY

İmza



Bu çalışma, Yıldız Teknik Üniversitesi Bilimsel Araştırma Proje Koordinatörlüğü'nün FYL-2023-5865 numaralı projesi ile desteklenmiştir.

*Bu tezi, akademik ve kişisel yolculuğumda bana rehberlik eden  
değerli hocam Doç. Dr. Mutlu AKAR'a ve her zaman yanımda olan aileme  
ithaf ediyorum.*



## TEŐEKKÜR

---

Bu tezin hazırlanmasında, bilgi ve deneyimlerini benimle cömertçe paylaşarak her aşamada bana yol gösteren, rehberliđi, sabrı ve desteđiyle alıřmamın tamamlanmasında büyük bir rol oynayan danışman hocam sayın Do. Dr. Mutlu AKAR'a en derin Őükranlarımı sunarım. Kendisi, bu süreçte hem akademik hem de diđer farklı alanlardaki tecrübesi ile bana rehberlik eden bir mentör olmuřtur.

Ayrıca, bu zorlu süreçte bilgi ve tecrübelerini benimle paylaşarak bana destek olan, her zaman yanımda hissettiđim sevgili ağabeyim Ömer Emre KARAAY'a gönülden teşekkür ederim. Onun yönlendirmeleri ve kıymetli katkıları, bu alıřmayı daha anlamlı kılmıřtır.

Bu alıřma, TÜBİTAK Bilim İnsanı Destek Programları Başkanlıđı (BİDEB) 2210-A Genel Yurt İi Yüksek Lisans Burs Programı kapsamında desteklenmiřtir.

Mina KARAAY

# İÇİNDEKİLER

---

<b>KISALTIMA LİSTESİ</b>	<b>viii</b>
<b>ŞEKİL LİSTESİ</b>	<b>x</b>
<b>TABLO LİSTESİ</b>	<b>xi</b>
<b>ÖZET</b>	<b>xii</b>
<b>ABSTRACT</b>	<b>xiii</b>
<b>1 GİRİŞ</b>	<b>1</b>
1.1 Tezin Amacı . . . . .	1
1.2 Literatür Özeti . . . . .	2
1.3 Hipotez . . . . .	3
<b>2 YÖNTEMLER</b>	<b>4</b>
2.1 Veri Setinin Tanımı . . . . .	4
2.2 Yöntemler . . . . .	8
2.2.1 Lojistik Regresyon Yöntemi . . . . .	8
2.2.2 Naive Bayes Yöntemi . . . . .	8
2.2.3 K-En Yakın Komşular Yöntemi . . . . .	8
2.2.4 Destek Vektör Makinesi Yöntemi . . . . .	9
2.2.5 Karar Ağacı Yöntemi . . . . .	9
2.2.6 Rastgele Orman Yöntemi . . . . .	9
2.2.7 Yapay Sinir Ağı Yöntemi . . . . .	9
2.2.8 Gradyan Artırma Yöntemi . . . . .	10
2.2.9 Aşırı Gradyan Artırma Yöntemi . . . . .	10
2.2.10 Kategorik Artırma Yöntemi . . . . .	10
<b>3 DENEYSEL SONUÇ</b>	<b>11</b>
3.1 Veri Manipülasyonu . . . . .	11
3.2 Makine Öğrenmesi . . . . .	12
3.2.1 Karışıklık Matrisi . . . . .	13
3.2.2 Standard Scaler . . . . .	14

3.2.3	GridSearchCV Fonksiyonu . . . . .	15
3.3	Sonuçların Karşılaştırılması . . . . .	16
<b>4</b>	<b>SONUÇ</b>	<b>26</b>
	<b>KAYNAKÇA</b>	<b>28</b>
	<b>TEZDEN ÜRETİLMİŞ YAYINLAR</b>	<b>32</b>



## KISALTMA LİSTESİ

---

AC	Accuracy (Doğruluk)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
AN	Actual Negative (Gerçek Negatif)
AP	Actual Positive (Gerçek Pozitif)
CatBoost	Categorical Boosting (Kategorik Artırma)
DT	Decision Tree (Karar Ağacı)
ELM	Extreme Learning Machine (Aşırı Öğrenme Makinesi)
F	F1-Score (F1-Skor)
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
GA	Genetic Algorithms (Genetik Algoritmalar)
GB	Gradient Boost (Gradyan Artırma)
KNN	K-Nearest Neighbors (K-En Yakın Komşular)
LR	Logistic Regression (Lojistik Regresyon)
Max	Maximum value (Maksimum değer)
Min	Minimum value (Minimum değer)
ML	Machine Learning (Makine Öğrenmesi)
MLA	Machine Learning Algorithms (Makine Öğrenmesi Algoritmaları)
NB	Naive Bayes (Naive Bayes)
PN	Predicted Negative (Tahmin Edilen Negatif)
PP	Predicted Positive (Tahmin Edilen Pozitif)
PR	Precision (Kesinlik)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)

Q1	Quarter 1 (1. eyrek)
Q2	Quarter 2 (2. eyrek)
Q3	Quarter 3 (3. eyrek)
RE	Recall (Duyarlılık)
RF	Random Forest (Rastgele Orman)
SE	Sensitivity (Hassasiyet)
SGD	Stochastic Gradient Descent (Stokastik Gradient İniři)
SP	Specificity (Özgüllük)
SVM	Support Vector Machine (Destek Vektör Makinesi)
TN	True Negative (Dođru Negatif)
TP	True Positive (Dođru Pozitif)
XGBoost	Extreme Gradient Boosting (Ařırı Gradyan Artırma)

## ŞEKİL LİSTESİ

---

<b>Şekil 2.1</b>	Veri kümesinin korelasyon analizi . . . . .	6
<b>Şekil 3.1</b>	LR yöntemine ait performans metriklerinin görselleştirilmesi . . .	18
<b>Şekil 3.2</b>	NB yöntemine ait performans metriklerinin görselleştirilmesi . . .	18
<b>Şekil 3.3</b>	KNN yöntemine ait performans metriklerinin görselleştirilmesi . .	19
<b>Şekil 3.4</b>	SVM yöntemine ait performans metriklerinin görselleştirilmesi . .	20
<b>Şekil 3.5</b>	SVM-RBF yöntemine ait performans metriklerinin görselleştirilmesi . . . . .	20
<b>Şekil 3.6</b>	ANN yöntemine ait performans metriklerinin görselleştirilmesi . .	21
<b>Şekil 3.7</b>	DT yöntemine ait performans metriklerinin görselleştirilmesi . . .	22
<b>Şekil 3.8</b>	RF yöntemine ait performans metriklerinin görselleştirilmesi . . .	22
<b>Şekil 3.9</b>	GB yöntemine ait performans metriklerinin görselleştirilmesi . . .	23
<b>Şekil 3.10</b>	XGBoost yöntemine ait performans metriklerinin görselleştirilmesi	24
<b>Şekil 3.11</b>	CatBoost yöntemine ait performans metriklerinin görselleştirilmesi	24

## TABLO LİSTESİ

---

<b>Tablo 2.1</b>	Kalp yetmezliği veri setinin özellikleri ve açıklamaları . . . . .	4
<b>Tablo 2.2</b>	Veri kümesinin açıklaması . . . . .	5
<b>Tablo 3.1</b>	Karışıklık matrisi . . . . .	13
<b>Tablo 3.2</b>	GridSearchCV uygulanmadan elde edilen sınıflandırma metriklerinin karşılaştırılması . . . . .	16
<b>Tablo 3.3</b>	GridSearchCV uygulanarak elde edilen sınıflandırma metriklerinin karşılaştırılması . . . . .	17
<b>Tablo 4.1</b>	Diğer makaleler ile sınıflandırma metriklerinin karşılaştırılması .	26

## Makine Öğrenimi Tekniklerini Kullanarak Kalp Hastalığı Tahminleri

Mina KARAÇAY

Matematik Anabilim Dalı  
Yüksek Lisans Tezi

Danışman: Doç. Dr. Mutlu AKAR

Makine öğrenimi, günümüzde en hızlı gelişen teknolojilerden biri olup pek çok farklı alanda geniş çapta uygulanmaktadır. Sağlık sektörü, bu yeni teknolojiden önemli ölçüde yararlanmaktadır. Son yıllarda, kalp krizi ve kalp yetmezliği tüm yaş gruplarında giderek daha yaygın hale gelmiştir. Kalp yetmezliği, çeşitli sebeplerden dolayı kalbin kanı etkili bir şekilde pompalayamadığı durumlarda meydana gelmektedir. Her yıl dünya genelinde yaklaşık 17,9 milyon kişi kalp hastalıkları nedeniyle hayatını kaybetmektedir. Bu çalışmada, 918 kayıt içeren bir veri seti analiz edilmiş; eksik veriler, aykırı değerler gibi unsurlar dikkate alınarak gerekli veri işlemleri gerçekleştirilmiştir. Standartlaştırmanın ardından, veri setine sınıflandırma amacıyla çeşitli makine öğrenimi algoritmaları uygulanmıştır. Amaç, en yüksek doğruluk, tahmin gücü ve ilgili performans ölçütlerini elde etmektir. Sınıflandırma modellerinin performansını artırmak için GridSearchCV fonksiyonu kullanılarak optimum parametreler belirlenmiş ve sonraki analizler bu parametrelerle yürütülmüştür.

**Anahtar Kelimeler:** GridSearchCV fonksiyonu, İkili sınıflandırma, Kalp hastalığı, Makine öğrenmesi.

## ABSTRACT

---

# Heart Disease Predictions Utilizing Machine Learning Techniques

Mina KARAÇAY

Department of Mathematics

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Mutlu AKAR

Machine learning is one of the fastest-growing technologies today and widely applied across various fields. The healthcare sector significantly benefits from this emerging technology. In recent years, heart attacks and heart failure have become increasingly prevalent across all age groups. Heart failure occurs when the heart is unable to pump blood effectively due to various underlying causes. Each year, approximately 17.9 million people die from heart disease worldwide. In this study, a dataset containing 918 records was analyzed, addressing missing data, outliers, and performing relevant data manipulations. Following standardization, various machine learning algorithms were applied to the dataset for classification purposes. The objective was to achieve the highest accuracy, predictive power, and related performance metrics. To enhance the performance metrics in the classification models, the GridSearchCV function was utilized to determine optimal parameters, and subsequent analyses were conducted using these parameters.

**Keywords:** Binary classification, GridSearchCV function, Heart disease, Machine learning.

---

YILDIZ TECHNICAL UNIVERSITY  
GRADUATE SCHOOL OF SCIENCE AND ENGINEERING

## 1.1 Tezin Amacı

Kalp hastalığı, kalp krizi ve kalp yetmezliğinin son zamanlarda tüm yaş gruplarında giderek daha yaygın hale gelmesiyle, küresel çapta önemli bir sağlık sorunu teşkil etmektedir [1]. Kalp yetmezliği, kalbin vücudun ihtiyaçlarını karşılayacak yeterli kanı pompalayamamasıyla ortaya çıkan, birden fazla organ yetmezliğine ve nihayetinde ölüme yol açan zayıflatıcı bir durumdur [2] [3].

Kalp yetmezliğinin başlıca nedenleri arasında koroner kalp hastalığı, diyabet, yüksek tansiyon ve HIV, madde bağımlılığı (alkol veya kokain), tiroid bozuklukları, aşırı vitamin E seviyeleri ile radyasyon veya kemoterapiden kaynaklanan hasar gibi diğer durumlar yer almaktadır [2].

Kalp hastalıkları üzerine yapılan araştırmalar uzun süredir Dünya Sağlık Örgütü'nün odak noktası olmuştur. 2016 yılında, dünya genelinde ölümlerin %31'ini oluşturan 17,9 milyondan fazla insan kalp ile ilgili durumlardan hayatını kaybetmiştir [4].

Makine Öğrenimi (ML), Yapay Zeka (AI) alanına ait olan ve günümüzde çeşitli alanlarda yaygın olarak uygulanan en ileri teknolojilerden biri olarak öne çıkmaktadır [5]. ML modelleri, hastalık durumlarını ve ilgili sağlık sonuçlarını tahmin etmek için giderek daha fazla kullanılmaktadır [6]. ML'in gizli kalıpları tespit etme ve verileri analiz etme konusundaki rolü hayati öneme sahiptir; çünkü kalp yetmezliği ve hasta sağkalımını tahmin etmede önemli bir başarı göstermiştir [7].

ML, veri biliminin temel bir unsuru olarak, sınıflandırmalar veya tahminler için algoritmaları eğiterek veri madenciliği çalışmaları sırasında önemli içgörülerini ortaya çıkarmak amacıyla istatistiksel alt teknikler kullanılmaktadır [8]. Bu süreç, ML modellerinin veri kümeleri üzerinde eğitilmesini ve ardından bu eğitilmiş modellerin ayrı test veri kümeleri üzerinde test edilmesini içerir.

Kalp yetmezliđi tahmini için makine öğreniminin kullanılması, klinisyenlere kalp yetmezliđi riski taşıyan hastaları belirlemek için paha biçilmez bilgiler ve karar verme araçları sunarak hasta sonuçlarını iyileştirme konusunda büyük bir potansiyel taşımaktadır [1].

Kalp yetmezliđi tahmini, makine öğreniminin dikkate değer bir uygulaması olarak öne çıkmaktadır. Bu süreçte, yaş, cinsiyet, göğüs ağrısı türü, dinlenme kan basıncı, kolesterol seviyeleri, açlık kan şekeri, dinlenme elektrokardiyogramı (EKG) ve maksimum kalp hızı gibi faktörlere dayalı olarak bir bireyin kalp yetmezliđi geliştirme olasılıđı belirlenmektedir [9].

Bu tez, on bir kritik klinik sađlık özelliđine dayalı olarak çeşitli veri madenciliđi teknikleri ve makine öğrenimi algoritmalarını (MLA) kullanarak kalp yetmezliđini tahmin etmek için yapılan bir çalışmayı sunmaktadır. Çalışmada kullanılan sınıflandırma algoritmaları şunlardır: K-En Yakın Komşu (KNN), Naive Bayes (NB), Lojistik Regresyon (LR), Destek Vektör Sınıflandırıcısı (SVM), Rastgele Orman (RF), Karar Ağacı (DT), Yapay Sinir Ađı (ANN), Gradyan Artırma (GB), Aşırı Gradient Artırma (XGB) ve Kategorik Artırma (CATB). Sınıflandırma raporunda özetlendiđi gibi doğruluk (AC), hassasiyet (SE), kesinlik (PR), özgülük (SP), duyarlılık (RE), F1-skor (F) gibi metrikleri geliştirmek için ilgili ML yöntemlerinin GridSearchCV işlevini kullandık. Bu yöntemler ve fonksiyonlarla en yüksek doğruluk değerine ulaşmayı amaçladık.

## 1.2 Literatür Özeti

Bu tezde kullanılan 918 hastadan oluşan kalp hastalıđı veri seti, Jain, Silva ve diđ. ile Bindela ve diđ. çalışmalarında da değerlendirilmiştir. Her üç çalışma, bu veri seti üzerinde farklı ML algoritmalarını analiz ederek kalp hastalıđını tahmin etmeye yönelik sonuçlar ortaya koymuştur. Jain'in çalışmasında, çapraz doğrulama kullanılan ve kullanılmayan ML modelleri karşılaştırılmış; LR sınıflandırıcısı %86,86 doğruluk oranıyla en yüksek performansı gösterirken, RF sınıflandırıcısı %92,86 ile en yüksek çapraz doğrulama skoruna ulaşmıştır [1]. Silva ve diđ., aynı veri seti üzerinde LR, SVM, DT, RF, SGD, NB ve KNN gibi yöntemleri incelemiş ve %85,86 doğruluk oranıyla SVM algoritmasının en iyi sonucu verdiđini raporlamışlardır [9]. Bindela ve diđ. ise, veri seti üzerinde SVM ve KNN algoritmalarını analiz etmiş, KNN modelinde doğruluk değerlerini farklı k parametreleri üzerinden hesaplamış ve RBF çekirdeđi ile kullanılan SVM algoritmasının %91,85 doğruluk oranıyla en yüksek performansa ulaştıđını ortaya koymuşlardır [10].

Saravanan ve Swaminathan, kalp yetmezliğini tahmin etmek için hibrit bir K-Means ve SVM algoritması önermiştir. Yazarlar, 299 hastadan oluşan bir veri kümesini kullanmıştır. Önerilen K-Means algoritması, k değeri 6 olarak ayarlandığında %93,33 ile en yüksek doğruluğa ulaşmıştır [11].

Zhang ve çalışma diğ., 299 kalp yetmezliği hastasına ait UCI veri setini kullanarak serum kreatinin, ejeksiyon fraksiyonu, hasta yaşı, kreatin fosfokinaz, serum sodyum ve takip süresi gibi özellikler üzerinde SVM, DT, RF, KNN ve GA-ELM algoritmalarını değerlendirmiştir. GA-ELM yöntemi, Genetik Algoritma (GA) ile Extreme Learning Machine (ELM) algoritmasının birleştirilmesiyle geliştirilmiştir. Çalışmada önerilen GA-ELM algoritması, %83.5 doğruluk oranıyla en yüksek tahmin performansını sergilemiştir [12].

Vijeta Sharma ve diğ., çalışmalarında UCI Repository'den erişilebilen Cleveland Kalp Hastalıkları veri setini kullanarak farklı makine öğrenimi algoritmalarının doğruluğunu analiz etmeyi hedeflemişlerdir. 1025 örnek ve 14 farklı özellik içeren bu veri seti, eğitim ve test veri kümelerine ayrılmıştır. Çalışmalarında RF, DT, SVM ve NB algoritmalarını kullanmışlardır. Sonuç olarak, RF algoritmasının %99 doğrulukla en iyi performansı gösterdiği, DT algoritmasının ise %85 doğrulukla en düşük performansa sahip olduğu tespit edilmiştir. Ayrıca, eğitim verilerinin artırılmasının daha yüksek doğruluk sağlayabileceği, ancak bu durumun sistemin daha karmaşık ve yavaş çalışmasına neden olabileceği belirtilmiştir [13].

### **1.3 Hipotez**

Makine öğrenmesi teknikleri, sağlık alanında önemli bir potansiyel sunmaktadır. Bu yöntemlerin, veri standardizasyonu için StandardScaler ve model optimizasyonu için GridSearchCV gibi araçlarla desteklenmesi, daha doğru ve güvenilir sonuçların elde edilmesine olanak tanımaktadır. Özellikle sağlık verilerinin analizi ve sınıflandırılmasında kullanılan makine öğrenmesi algoritmaları, tanı ve tedavi süreçlerinin hızlandırılmasında sağlık çalışanlarına önemli bir destek sağlayabilir. Bu sayede, hastalıkların erken teşhis edilmesi ve uygun tedavi planlarının belirlenmesi süreçlerinde zaman kazandırarak hasta sonuçlarının iyileştirilmesine katkıda bulunulabilir. Bu hipotez, makine öğrenmesinin sağlık sektöründe daha etkili bir şekilde kullanılması için bilimsel araştırmaların temelini oluşturabilir.

## 2 YÖNTEMLER

Bu çalışmanın amacı, veri kümesindeki gerekli veri manipülasyon işlemlerini gerçekleştirdikten sonra, StandardScaler ve GridSearchCV gibi fonksiyonlardan yararlanarak on bir farklı sınıflandırma yöntemi ile mevcut veri kümesi için en uygun sınıflandırma modelini belirlemektir.

### 2.1 Veri Setinin Tanımı

**Tablo 2.1** Kalp yetmezliği veri setinin özellikleri ve açıklamaları

Özellik Adı	Açıklama
Age	Hastanın yaşı (Yıl)
Sex	Hastanın cinsiyeti (E: Erkek, K: Kadın)
ChestPainType	Göğüs ağrısı türü (TA: Tipik Anjina, ATA: Atipik Anjina, NAP: Anjinal Olmayan Ağrı, ASY: Asemptomatik)
RestingBP	Dinlenme sırasındaki kan basıncı (mm Hg)
Cholesterol	Serum kolesterol seviyesi (mg/dl)
FastingBS	Açlık kan şekeri (1: Eğer açlık kan şekeri > 120 mg/dl ise, 0: Diğer durumlar)
RestingECG	Dinlenme elektrokardiyogram sonuçları (Normal: Normal, ST: ST-T Dalga Anormalliği, LVH: Olası veya Kesin Sol Ventrikül Hipertrofisi)
MaxHR	Elde edilen maksimum kalp hızı (60 ile 202 arasında sayısal değer)
ExerciseAngina	Egzersizle tetiklenen anjina (E: Evet, H: Hayır)
Oldpeak	ST segment çöküşü (Sayısal değer)
ST_Slope	Egzersiz sırasında elde edilen maksimum ST segment eğimi (Yukarı: Yukarı eğimli, Düz: Düz, Aşağı: Aşağı eğimli)
HeartDisease	Kalp hastalığı teşhisi (1: Kalp hastalığı, 0: Normal)

Tablo 2.1, veri kümesindeki özellikleri ve bunlara karşılık gelen açıklamaları sunmaktadır.

Bu çalışmada kullanılan kalp hastalığı veri kümesi [14], 918 kayıttan oluşmakta

olup, yaş, cinsiyet, kolesterol seviyeleri, maksimum kalp hızı, egzersizle tetiklenen angina, göğüs ağrısı tipi, dinlenme elektrokardiyogramı (EKG) sonuçları, eski tepe noktası ve ST eğimi gibi hasta özellikleri ile ilgili verileri içermektedir. Bu özellikler, veri içerisindeki kalıpların tanımlanmasına yardımcı olarak modelin öğrenmesini ve doğru kümeler oluşturmasını sağlamaktadır. Bu veri kümesi, bağımsız olarak mevcut olan birkaç kalp hastalığı veri kümesinin birleştirilmesiyle oluşturulmuştur. Ortak 11 özelliğe dayalı beş farklı kalp hastalığı veri kümesinin birleştirilmesiyle oluşturulan bu veri kümesi, araştırma amaçlı olarak şu anda mevcut olan en büyük kalp hastalığı veri kümesini sunmaktadır. Veri kümesi Kaggle platformunda mevcuttur, ilgili çalışmalarda kullanılmıştır [10][1][9].

**Tablo 2.2** Veri kümesinin açıklaması

	Age	RestingBP	Cholesterol	FastingBS	MaxHR	Oldpeak	HeartDisease
<b>count</b>	918	918	918	918	918	918	918
<b>mean</b>	53.51	132.40	198.80	0.23	136.81	0.89	0.55
<b>std</b>	9.43	18.51	109.38	0.42	25.46	1.07	0.50
<b>min</b>	28	0	0	0	60	-2.6	0
<b>Q1</b>	47	120	173.25	0	120	0	0
<b>Q2</b>	54	130	223	0	138	0.6	0
<b>Q3</b>	60	140	267	0	156	1.5	1
<b>max</b>	77	200	603	1	202	6.2	1

Tablo 2.2, 918 bireyden oluşan veri kümesine ilişkin özet istatistiksel bilgileri sunmaktadır. Bu analizde kullanılan Python kodu yalnızca tam sayı ve ondalık değerleri işlemekte olup, veri kümesinde yer alan yaş (Age), dinlenme kan basıncı (RestingBP), kolesterol (Cholesterol), açlık kan şekeri (FastingBS), maksimum kalp hızı (MaxHR), eski pike (Oldpeak) ve kalp hastalığı durumu (HeartDisease) gibi özelliklerin temel istatistikleri hesaplanmıştır. Her bir özellik için örnek sayısı (count), ortalama değer (mean), standart sapma (std), minimum değer (min), çeyrek değerler (Quarter 1 - Q1, Quarter 2 - Q2, Quarter 3 - Q3) ve maksimum değer (max) verilmiştir.


Bu özet tablo, veri kümesinin genel yapısını ve özelliklerin dağılımını anlamak için önemli bir referans sunmaktadır. Özellikle, bazı değişkenlerde (örneğin, RestingBP ve Cholesterol) sıfır değerlerinin bulunduğu gözlemlenmiştir; bu durum veri eksikliği veya anormal veri girişinden kaynaklanıyor olabilir. Bu gibi durumların, veri ön işleme aşamasında düzeltilmesi gerekebilir.

- Q1 (Quarter 1 - 1. Çeyrek): Veri değerlerinin %25'inin bu değer altında

olduğunu ifade etmektedir. Örneğin, Age değişkeni için Q1 değeri 47 olup, bireylerin %25'inin 47 yaş ve altında olduğu görülmektedir.

- Q2 (Quarter 2 - 2. Çeyrek/Medyan): Veri değerlerinin ortanca (medyan) değeridir ve bu, veri kümesindeki gözlemlerin %50'sinin bu değer altında, %50'sinin ise üstünde olduğunu ifade etmektedir. Örneğin, Age değişkeni için Q2 değeri 54 olarak hesaplanmıştır.
- Q3 (Quarter 3 - 3. Çeyrek): Veri değerlerinin %75'inin bu değer altında olduğunu göstermektedir. Örneğin, Age değişkeni için Q3 değeri 60 olarak belirlenmiştir.

Ayrıca, FastingBS değişkeninin çoğunlukla sıfır olduğu görülmekte, bu durum veri kümesindeki bireylerin büyük bir kısmının normal açlık kan şekeri seviyelerine sahip olduğunu göstermektedir. Buna karşın, RestingBP ve Cholesterol değişkenlerindeki sıfır değerlerinin, hatalı veya eksik veri kaynaklı olabileceği düşünülmektedir. Bu analiz sonuçları, modelleme sürecinde özellik mühendisliği ve veri ön işleme aşamaları için önemli bir temel oluşturabilir.



Şekil 2.1 Veri kümesinin korelasyon analizi

Şekil 2.1, korelasyon matrisi ile ısı haritasını göstermektedir. Korelasyon matrisi, veri kümesindeki değişkenler arasındaki ilişkileri (korelasyonları) sunarken, ısı haritası bu korelasyonları renk geçişleriyle görselleştirerek yorumlanmasını kolaylaştırmaktadır.

- +1: Güçlü pozitif korelasyon.
- 1: Güçlü negatif korelasyon.
- 0: Korelasyon yok.

#### Kalp Hastalığı

- ExerciseAngina ile HeartDisease arasında orta derecede güçlü bir pozitif korelasyon bulunmaktadır (0.55). Bu, egzersizle tetiklenen anjina yaşayan bireylerin kalp hastalığına yakalanma olasılığının daha yüksek olduğunu göstermektedir.
- ST\_Slope, HeartDisease ile güçlü bir pozitif korelasyon göstermektedir (0.60), bu da stres testleri sırasında ST segmentindeki eğim değişikliklerinin kalp hastalığı riskiyle ilişkili olduğunu göstermektedir.
- Oldpeak değişkeni de HeartDisease ile orta derecede pozitif bir korelasyon sergilemektedir (0.55). Bu, egzersiz stres testleri sırasında gözlemlenen ST segmentindeki depresyon ile kalp hastalığı arasındaki ilişkiyi yansıtmaktadır.
- MaxHR, HeartDisease ile negatif bir korelasyona sahiptir (-0.38). Bu durum, maksimum kalp hızı düşük olan bireylerin kalp hastalığı açısından daha yüksek risk taşıyabileceğini göstermektedir.

#### Diğer Değişkenler

- MaxHR ve Age arasında -0.38'lik negatif bir korelasyon bulunmaktadır; bu, yaş arttıkça maksimum kalp hızının azalma eğiliminde olduğunu ima etmektedir.
- RestingBP, diğer değişkenlerle zayıf korelasyonlar göstermekte olup, bu durum dinlenme halindeki kan basıncının veri kümesindeki diğer faktörlerle güçlü bir ilişki içinde olmadığını göstermektedir.
- ChestPainType, HeartDisease ile pozitif yönde bir korelasyona sahiptir (0.44); bu, belirli göğüs ağrısı tiplerinin kalp hastalığı öngörüsünde bulunabileceğini göstermektedir.

- Oldpeak ve ST\_Slope, güçlü bir pozitif korelasyon sergilemektedir (0.61), bu da her iki değişkenin kalp hastalığı belirtileri ve tanısal göstergeleri ile yakından ilişkili olduğunu göstermektedir.

## **2.2 Yöntemler**

### **2.2.1 Lojistik Regresyon Yöntemi**

Klasik bir gözetimli öğrenme yöntemi olan LR, genellikle ikili sınıflandırma problemlerinin çözümünde tercih edilmektedir [15]. LR modeli, genellikle veri setindeki iki kategoriden birine ait sınıf üyelik olasılığını hesaplar [16]. Özellik sayısının veri miktarını aştığı durumlarda lojistik regresyon kullanılmamalıdır, zira bu, aşırı öğrenmeye yol açabilir [17].

### **2.2.2 Naive Bayes Yöntemi**

NB sınıflandırıcı, Bayes teoremine dayanan ve özellikler arasında güçlü bağımsızlık varsayımına sahip basit olasılıksal modellerden oluşmaktadır [18]. Bu sınıflandırıcılar için, sınıf verildiğinde özelliklerin bağımsız olduğu varsayımı altında, özellik vektörü sınıf etiketinden bağımsız hale gelir ve böylece öğrenme süreci önemli ölçüde hızlandırılabilir. Bu varsayım gerçekçi görünmese de, Naive Bayes sınıflandırıcı pratikte oldukça etkilidir ve çoğu zaman daha karmaşık yöntemleri geride bırakmaktadır [19].

### **2.2.3 K-En Yakın Komşular Yöntemi**

KNN algoritması, hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılan, yeni verilerle mevcut veriler arasındaki benzerlikleri karşılaştırarak benzer verileri bir araya getiren bir denetimli öğrenme yöntemidir. Uygulaması kolay olan KNN, özellikle büyük eğitim veri setleri için etkili bir seçenek olarak değerlendirilmektedir.[20]. KNN sınıflandırıcı, yeni bir gözleme en yakın k veri noktasını belirleyerek, bu k komşunun çoğunluk sınıfına göre sınıf etiketini tahmin eder. Yeni gözlem ile mevcut veri noktaları arasındaki benzerlik, Öklid, Manhattan veya Minkowski mesafeleri kullanılarak ölçülebilir. KNN, sadeliği ve etkinliği nedeniyle yaygın olarak kullanılan bir algoritmadır ve bankacılık, sağlık ve görüntü tanıma gibi çeşitli sektörlerde uygulanmaktadır [1].

#### **2.2.4 Destek Vektör Makinesi Yöntemi**

İlk olarak Vapnik tarafından tanıtılan SVM, doğruluk ile genelleme hatasını dengeleyen bir öğrenme tekniği olan gözetimli öğrenme algoritmaları sınıfıdır. SVM'ler, veri noktalarını ayıran ve bir sınıfa ait örnekleri hiper düzlemin bir tarafına, diğer sınıfa ait örnekleri ise karşı tarafa yerleştiren bir hiper düzlem oluşturur [21].

#### **2.2.5 Karar Ağacı Yöntemi**

DT algoritması, veri kümesini daha küçük alt kümelere bölen bir ağaç yapısına sahiptir. Bir karar düğümü iki veya daha fazla yola dallanabilirken, nihai bir sonuç yaprak düğüm ile temsil edilebilir. Karar ağacının en üstünde yer alan kök düğüm bulunur. Bu algoritma, entropi ve bilgi kazancı kavramlarını kullanır. Entropi, bir örneğin homojenliğini ölçmek için kullanılır. Karar ağacı oluşturma süreci, en yüksek bilgi kazancını sağlayan özelliklerin belirlenmesini içerir. Son olarak, en yüksek bilgi kazancına sahip özellik karar düğümü olarak seçilir ve bilgi kazancı sıfır olan dallar yaprak düğümler olarak atanır [22]

#### **2.2.6 Rastgele Orman Yöntemi**

RF, her ağacın rastgele egemenlik kullanılarak büyütüldüğü ve bir dizi karar ağacından oluşan çok yönlü bir sınıflandırıcıdır. Bu yöntem, eğitim sırasında hem veri alt örnekleme hem de düğüm testlerinin rastgele seçimiyle çeşitlilik sağlayarak sınıflandırma performansını artırır [23]. RF kullanılırken iki tür veri kullanılır: rastgele seçilen bir özellik veri kümesi ve orijinal veri kümesi. Tüm veri kümesinin üçte biri makine öğrenimi algoritmasını eğitmek için kullanılırken, geri kalan üçte ikisi yeni ağaçlar eklendikçe önyargısız sınıflandırma hatasını tahmin etmek için kullanılır [24]. Nihai sınıf kararı, tüm ağaçların sınıflandırma tahminlerinin çoğunluk oylaması ile birleştirilmesiyle belirlenir.

#### **2.2.7 Yapay Sinir Ağı Yöntemi**

Çok katmanlı Algılayıcı (Multilayer Perceptron) ilk olarak 1969 yılında M. Minsky ve S. Papert tarafından tanıtılmıştır. Girdi ve çıktı düğümleri arasında bir veya daha fazla düğüm katmanına sahip bir ANN, çok katmanlı bir ağ olarak adlandırılır. Çok katmanlı bir ağın mimarisi veya topolojisi, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Girdi düğümleri, değerleri ilk gizli katmana iletir; bu katman ise değerleri sonraki katmanlara aktarır ve bu süreç çıktı üretilene kadar devam eder [21].

### **2.2.8 Gradyan Artırma Yöntemi**

GB makine öğreniminde denetimli teknikler altında yer alan ve genellikle karar ağaçları gibi zayıf tahmin modellerinin bir koleksiyonunu kullanarak çalışan ağaç tabanlı bir algoritmadır. Bu teknikte, her bir tahminci seleftinin hatalarını düzelterek modelin doğruluğunu artırır [25]. Temel ilke, yeni temel öğrencileri tüm topluluğa ait kayıp fonksiyonunun negatif gradyanıyla hizalamak ve böylece genel model performansını geliştirmektir. Herhangi bir kayıp fonksiyonu kullanılabilir de, genellikle kare hata kaybı tercih edilir ve bu, ardışık hata düzeltme süreci oluşturur. GB makinelerinin esnekliği, araştırmacıların göreve özel kayıp fonksiyonları seçmesine veya tasarlamasına olanak tanır; bu da onu çeşitli öngörülse modelleme görevleri için son derece çok yönlü bir araç haline getirir. Gradyan inişi çerçevesine dayanan bu yöntem, güçlendirme algoritmalarının istatistiksel temellerini vurgulamaktadır [26].

### **2.2.9 Aşırı Gradyan Artırma Yöntemi**

XGBoost ve GB, her ikisi de zayıf öğrencileri güçlendirmek için gradyan inişi çerçevesini kullanan topluluk ağaç yöntemleridir. Ancak, XGBoost, temel GB mimarisini sistem optimizasyonları ve algoritmik iyileştirmelerle geliştirir. XGBoost sınıflandırıcısı, topluluk tekniğiyle çalışarak karar ağaçlarının bir topluluğunu oluşturur ve her ağaç, bir önceki ağacın tahmin hatalarını düzelterek model performansını artırır [27]. Bu süreç yinelemeli olarak devam eder ve her yeni sınıflandırıcı, önceki sınıflandırıcıların yetersiz kaldığı alanlara odaklanır [28]

### **2.2.10 Kategorik Artırma Yöntemi**

CatBoost, karar ağaçlarında gradyan artırma tekniğini kullanan ve kategorik özellikleri işleme konusunda etkili olan bir algoritmadır [29] [30]. Kategorik özellikleri otomatik olarak sayısal değerlere dönüştürerek kapsamlı ön işleme gereksinimini en aza indirir. CatBoost ayrıca, aşırı öğrenme belirtileri algılandığında eğitimi durduran bir aşırı öğrenme dedektörü içermektedir [31].

# 3

## DENEYSEL SONUÇ

---

Veri kümesine çeşitli veri işleme teknikleri uygulandıktan sonra, önerilen ML modelleri Python programlama dili kullanılarak uygulanmıştır. Bu bölümde, bu modellerin veri kümesine uygulanmasından elde edilen sonuçlar sunulmaktadır. Sonuçlar, GridSearchCV fonksiyonu ile ve GridSearchCV fonksiyonu olmadan elde edilen doğruluk değerlerine göre karşılaştırılmaktadır.

### 3.1 Veri Manipülasyonu

Veri analitiği sürecinde, güvenilir sonuçlar elde edebilmek için veri setinin uygun hale getirilmesi kritik bir adımdır. Bu çalışmada, ikili sınıflandırma modellemesi öncesinde veri setine çeşitli manipülasyonlar uygulanmıştır. İlk olarak, veri setindeki öznitelikler incelenmiş ve "RestingBP" ile "Cholesterol" (kolesterol) sütunlarının sıfır içeren satırları, bu değerlerin fizyolojik açıdan sıfır olmasının mümkün olmaması nedeniyle veri setinden çıkarılmıştır. Bu işlem sonucunda, veri setindeki toplam örnek sayısı 918'den 746'ya düşmüştür. Bu adım, istatistiksel analiz ve makine öğrenimi modellerinin doğruluğunu artırmak amacıyla yapılmıştır.

Sonraki adımda, kategorik değişkenler numerik formata dönüştürülmüştür. Örneğin, "Sex" sütunundaki 'F' ve 'M' değerleri sırasıyla 0 ve 1 ile değiştirilmiştir. Benzer şekilde, "ChestPainType", "RestingECG", "ST\_Slope" ve "ExerciseAngina" gibi değişkenler, ilgili kategorik değerlerden sırasıyla sayısal kodlara dönüştürülmüştür. Bu dönüşümler, sınıflandırma modellerinde kategorik değişkenlerin etkin bir şekilde kullanılmasını sağlamıştır. Böylece veri seti, ikili sınıflandırma modelleri için uygun bir sayısal forma getirilmiştir.

Bu manipülasyonlar, eksik veya anlamlı olmayan değerlerin temizlenmesi ve kategorik değişkenlerin sayısal forma dönüştürülmesi gibi veri ön işleme süreçlerini kapsamaktadır. Bu işlemler sayesinde, veri setindeki potansiyel tutarsızlıkların ve eksikliklerin model performansı üzerindeki olumsuz etkileri en aza indirilmiş, veri seti daha sağlam ve analiz edilebilir bir hale getirilmiştir. Bu adımlar, analiz

sürecinde kullanılan veri kalitesini artırarak daha doğru ve güvenilir sonuçlar elde edilmesini sağlamıştır.

### 3.2 Makine Öğrenmesi

Veri seti üzerinde gerçekleştirilen manipülasyonların ardından, makine öğrenmesi modellerinin performansını değerlendirmek için çeşitli adımlar izlenmiştir. İlk olarak, temizlenmiş ve düzenlenmiş veri seti, eğitim ve test verileri olmak üzere %80 eğitim ve %20 test oranında ayrılmıştır. Bu ayırım, modellerin performansını bağımsız bir test veri seti üzerinde objektif bir şekilde değerlendirmek amacıyla yapılmıştır. Daha sonra, eğitim ve test veri setleri StandardScaler yöntemi kullanılarak standartlaştırılmıştır. Bu işlem, değişkenlerin farklı ölçeklerden etkilenmesini engellemek ve algoritmaların daha etkin bir şekilde çalışmasını sağlamak amacıyla gerçekleştirilmiştir.

Standartlaştırma işleminin ardından, 11 farklı makine öğrenmesi yöntemi uygulanmıştır. Her bir model, eğitim veri seti üzerinde eğitilmiş ve test veri seti üzerinde doğrulama işlemi gerçekleştirilmiştir. Bu süreçte, doğruluk, kesinlik, duyarlılık, hassiyet ve özgüllük gibi çeşitli performans metrikleri hesaplanmıştır. Bu ilk adım, temel model performansını değerlendirmek ve modellerin başlangıç parametreleriyle nasıl performans gösterdiğini anlamak amacıyla yapılmıştır.

İkinci aşamada, makine öğrenmesi modellerinin performansını optimize etmek için hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreçte, standartlaştırılmış veri seti üzerinde GridSearchCV yöntemi kullanılarak her bir algoritmanın en iyi hiperparametreleri belirlenmiştir. GridSearchCV, belirlenen hiperparametre aralıklarında çapraz doğrulama yaparak en iyi parametre kombinasyonlarını seçmiştir. Optimum parametreler belirlendikten sonra, her bir model bu parametrelerle yeniden eğitilmiş ve test veri seti üzerinde doğrulama yapılmıştır. Bu süreç sonunda, doğruluk, kesinlik, duyarlılık, F1 skoru ve özgüllük gibi performans metrikleri yeniden hesaplanmış ve başlangıçtaki modellerle karşılaştırılmıştır.

Bu çalışma, hem temel model performanslarının hem de hiperparametre optimizasyonu ile elde edilen performansların değerlendirilmesini içermektedir. Sonuçlar, hiperparametre optimizasyonunun model performansını artırdığını ve daha tutarlı sonuçlar elde edilmesini sağladığını göstermektedir. Ayrıca, bu yöntem sayesinde, veri setine en uygun algoritmanın seçimi daha bilinçli bir şekilde yapılmıştır.

### 3.2.1 Karışıklık Matrisi

Karışıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir analiz aracıdır [10]. Bu matris, modelin tahmin ettiği sınıflar ile gerçek sınıflar arasındaki ilişkiyi görselleştirerek, modelin doğru ve yanlış tahminlerini detaylı bir şekilde inceleme imkanı sunar. Aşağıda, pozitif ve negatif sınıflar için tahmin edilen ve gerçek sonuçları gösteren bir karışıklık matrisi yer almaktadır.

**Tablo 3.1** Karışıklık matrisi

	<b>AP</b>	<b>AN</b>
<b>PP</b>	TP	FP
<b>PN</b>	FN	TN

Tablo 3.1, sınıflandırma modelinin pozitif ve negatif sınıflar için yaptığı tahminlerin gerçek sınıflarla uyumunu özetlemektedir. Bu tablo, modelin performansını değerlendirmek için kritik bir araçtır ve sınıflandırma başarı oranlarını hesaplamak için temel oluşturur.

Bu bağlamda, karışıklık matrisindeki dört ana bileşen şu şekilde tanımlanmaktadır:

- **Doğru Pozitifler (TP):** Pozitif sınıfın doğru bir şekilde pozitif olarak tahmin edilmesi durumunu ifade eder.
- **Yanlış Pozitifler (FP):** Negatif bir sınıfın yanlış bir şekilde pozitif olarak tahmin edilmesi durumudur.
- **Doğru Negatifler (TN):** Negatif sınıfın doğru bir şekilde negatif olarak tahmin edilmesini ifade eder.
- **Yanlış Negatifler (FN):** Pozitif bir sınıfın yanlış bir şekilde negatif olarak tahmin edilmesini ifade eder.

Bu bileşenler, tahmin edilen ve gerçek sınıf etiketleri arasındaki uyumun değerlendirilmesi açısından büyük önem taşır. Doğru sınıflandırmalar, tahmin edilen pozitifler ve tahmin edilen negatifler ile temsil edilirken, yanlış sınıflandırmalar, yanlış pozitifler ve yanlış negatifler ile ifade edilir. Yanlış pozitifler, negatif bir örneğin yanlışlıkla pozitif olarak sınıflandırılması durumunu işaret ederken, yanlış negatifler, pozitif bir örneğin yanlışlıkla negatif olarak sınıflandırılmasını ifade eder. Bu tür yanlış sınıflandırmalar, modelin tahminlerinde

gerçek sonuçlardan sapma gösterdiği durumları vurgulamakta ve modelin iyileştirilmesi gereken yönlerine dikkat çekmektedir [32].

Bu değerler kullanılarak, çeşitli performans ölçütleri şu şekilde hesaplanabilir [32][33]:

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

$$PR = \frac{TP}{TP + FP} \quad (3.2)$$

$$RE/SE = \frac{TP}{TP + FN} \quad (3.3)$$

$$F = 2 \times \frac{PR \times RE}{PR + RE} \quad (3.4)$$

$$SP = \frac{TN}{TN + FP} \quad (3.5)$$

Bu metrikler, bir sınıflandırma modelinin performansını farklı yönlerden değerlendirmek için kullanılır. Doğruluk, modelin toplam doğru tahminlerinin, toplam tahminlere oranıdır. Tüm sınıflandırmaların genel olarak ne kadar doğru olduğunu ölçer. Kesinlik, pozitif sınıfların ne kadar doğru bir şekilde tahmin edildiğini gösterir. Duyarlılık, modelin gerçek pozitifleri ne kadar iyi yakaladığını ölçerken, F1-Skoru, kesinlik ve duyarlılığı dengeli bir şekilde birleştirerek modelin performansını özetler. Ayrıca, Özgüllük, negatif sınıfların doğru tahmin edilme oranını belirtir.

### 3.2.2 Standard Scaler

Python'daki StandardScaler fonksiyonu, ML modellerinde yaygın bir ön işleme adımı olan veri standardizasyonu için kullanılır. Z-puanı normalizasyonunu uygulayan StandardScaler tekniği, her bir değerden ilgili özelliğin ortalamasını çıkarıp sonucu özelliğin standart sapmasına (s) bölerek veriyi standartlaştırır [34].  $x$  değişkeninin ortalaması  $\bar{x}$  olsun.  $x_i$  değeri, Denklem (3.6) ile  $x'_i$  olarak dönüştürülür (ölçeklendirilir)[34].

$$x'_i = \frac{x_i - \bar{x}}{s} \quad (3.6)$$

Bu işlem verilerimizi normalize ederek ortalama değerin sıfırı aşmamasını ve standart sapmanın biri geçmemesini sağlar. Bu işlem, algoritmayı uygulamadan önceki verilerin tam tersi bir etkisini ortaya koyarak daha iyi sonuçlar elde edilmesine olanak tanır [35]. StandardScaler'ı kullanmanın, veri kümesindeki sayısal özellikler arasında tutarlı bir ölçek sağlama avantajı vardır. Makine öğrenmesi tekniklerini kullanırken, veri boyutuna duyarlı olmaya yardımcı olabilir [34]. Bu dönüşüm, verinin tutarlı bir dağılıma yeniden ölçeklendirilmesini sağlar ve özellikle model eğitimi sırasında faydalıdır. StandardScaler fonksiyonu ilgili çalışmalarda da kullanılmıştır [36].

### 3.2.3 GridSearchCV Fonksiyonu

ML modelleri hiperparametre kombinasyonlarını optimize etmek için sistematik bir tarama gerektirir [37]. GridSearchCV, makine öğrenimi modellerinin hiperparametrelerini optimize etmek için kullanılan bir yöntemdir. Hiperparametreler, model eğitimi öncesinde kullanıcının belirlemesi gereken ve öğrenme sürecini yöneten parametrelerdir. Tanımlanan parametre kombinasyonlarını sistematik olarak test eden ve en iyi performansı sağlayan parametre setini belirleyen bir yöntemdir. Bu işlem, tahmin edici modeli (estimator) ve bir parametre ızgarasını (parameter grid) kullanarak, tüm kombinasyonları değerlendirir ve en iyi doğruluğu sunan sonuçları optimize eder [38]. Bu yöntem, LR, KNN, SVM ve XGBoost gibi modellerde hiperparametre optimizasyonu için yaygın olarak kullanılır. Amaç, aşırı öğrenme (overfitting) ve yetersiz öğrenme (underfitting) arasında bir denge sağlayarak hatayı azaltmak ve model doğruluğunu artırmaktır [39]. Verma ve Yadav, Alemerien ve arkadaşları çalışmalarında daha iyi performans değerlerine ulaşabilmek için GridSearchCV fonksiyonundan destek almışlardır [40][41].

Bu tezde, GridSearchCV fonksiyonu ile ve GridSearchCV fonksiyonu olmadan on bir farklı ML modeli uygulanmış ve sonuçlar karşılaştırılmıştır. Veri kümesi, %80 eğitim ve %20 test oranında bölünmüştür. Ayrıca, GridSearchCV kullanılarak ve kullanılmadan yapılan tüm sınıflandırmalarda StandardScaler fonksiyonu ile veri standardizasyonu gerçekleştirilmiştir.

### 3.3 Sonuçların Karşılaştırılması

Tablo 3.2, GridSearchCV fonksiyonu uygulanmadan elde edilen, ikili sınıflandırmada kullanılan farklı makine öğrenmesi algoritmalarına ait sınıflandırma metriklerini karşılaştırmalı olarak sunmaktadır. Bu tablo, belirli bir veri kümesi üzerinde en iyi performansı sağlayan modeli seçmek ve genel bir referans noktası oluşturmak için önemli bilgiler sağlamaktadır.

**Tablo 3.2** GridSearchCV uygulanmadan elde edilen sınıflandırma metriklerinin karşılaştırılması

MLA	AC(%)	PR(%)	RE/SE(%)	F(%)	SP(%)
NB	86	89.19	83.54	86.27	88.73
LR	86.67	88.31	86.08	87.18	87.32
KNN	90.67	90.12	92.41	91.25	88.73
SVM-RBF	88	90.67	86.08	88.31	90.14
SVM	91.33	90.24	93.67	91.93	88.73
ANN	86	90.28	82.28	86.09	90.14
RF	90	93.24	87.34	90.20	92.96
DT	81.33	84	79.75	81.82	83.10
GB	88.67	93.06	84.81	88.74	92.96
XGBoost	90	94.44	86.08	90.07	94.37
CatBoost	89.33	93.15	86.08	89.47	92.96

Tablo 3.2 incelendiğinde, en yüksek doğruluk değeri %91.33 ile SVM yöntemi tarafından elde edilmiştir. Kesinlik açısından ise en yüksek değer %94.44 ile XGBoost yönteminde gözlemlenmiştir. Duyarlılık/hassasiyet metriklerinde %93.67 ile SVM yöntemi öne çıkmaktadır. En yüksek F1-skora %91.93 ile yine SVM yöntemi ulaşırken, özgüllük açısından en yüksek değer %94.37 ile XGBoost yöntemi tarafından sağlanmıştır.

Tablo 3.3 incelendiğinde, GridSearchCV uygulanarak elde edilen sonuçlara göre en yüksek doğruluk değeri %92 ile XGBoost ve CatBoost yöntemlerinde elde edilmiştir. Kesinlik açısından en yüksek değer %95.83 ile RF yönteminde gözlemlenmiştir. Duyarlılık/hassasiyet metriklerinde %91.14 ile KNN, ANN, CatBoost yöntemleri öne çıkmaktadır. F1-skora bakıldığında en yüksek değer %92.31 ile CatBoost yöntemi tarafından sağlanmıştır. Özgüllük açısından ise en yüksek değer %95.77 ile RF yöntemi ile elde edilmiştir. Bu sonuçlar, GridSearchCV ile yapılan optimizasyonların bazı algoritmaların performansını artırdığını göstermektedir.

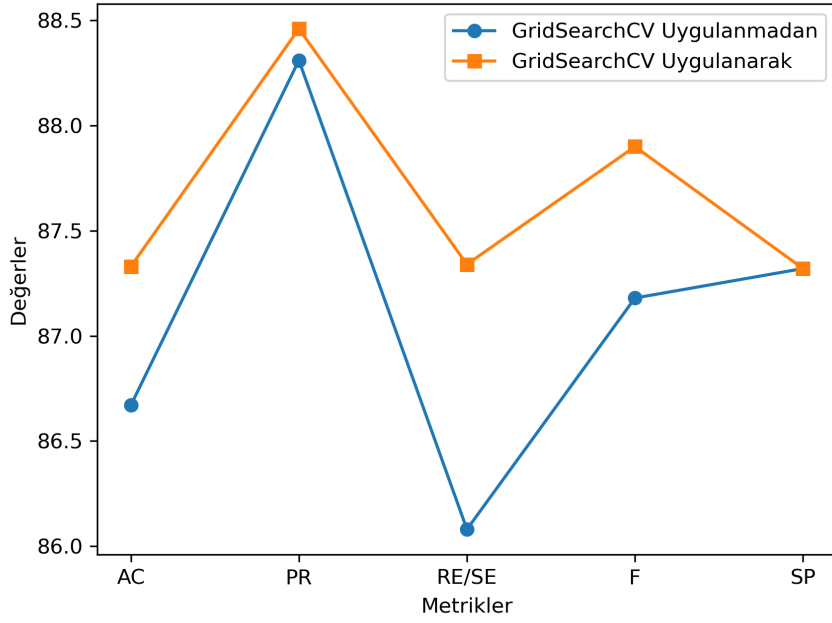
**Tablo 3.3** GridSearchCV uygulanarak elde edilen sınıflandırma metriklerinin karşılaştırılması

MLA	AC(%)	PR(%)	RE/SE(%)	F(%)	SP(%)
NB	86	89.19	83.54	86.27	88.73
LR	87.33	88.46	87.34	87.90	87.32
KNN	91.33	92.31	91.14	91.72	91.55
SVM-RBF	88.67	89.74	88.61	89.17	88.73
SVM	88	87.65	89.87	88.75	85.92
ANN	90	90	91.14	90.57	88.73
RF	91.33	95.83	87.34	91.39	95.77
DT	84	92.31	75.95	83.33	92.96
GB	88.67	94.29	83.54	88.59	94.37
XGBoost	92	94.67	89.87	92.21	94.37
CatBoost	92	93.51	91.14	92.31	92.96

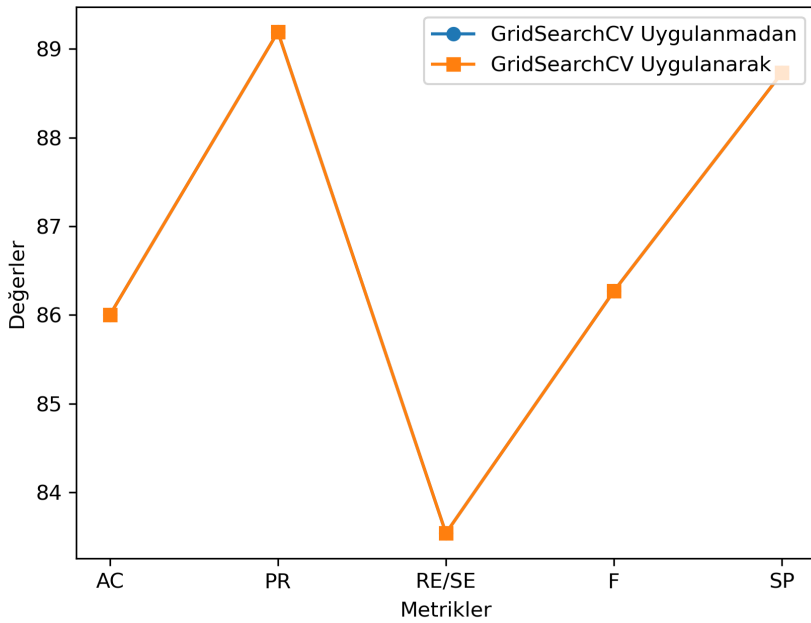
GridSearchCV fonksiyonu uygulanmadan ve uygulanarak elde edilen doğruluk değerlerine bakıldığında, GridSearchCV uygulanmadan en yüksek doğruluk değeri %91.33 ile SVM yöntemine aittir. GridSearchCV uygulandığında ise en yüksek doğruluk değeri %92 ile XGBoost ve CatBoost yöntemlerinde elde edilmiştir. Bu sonuç, GridSearchCV'nin doğruluk oranlarını iyileştirmede etkili olduğunu göstermektedir.

Şekil 3.1, LR yöntemi için GridSearchCV yöntemi uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerinin karşılaştırmasını görselleştirmektedir. GridSearchCV uygulanmadan önce LR yöntemi için doğruluk %86.67 iken, GridSearchCV sonrası bu değer %87.33'e yükselmiştir. Kesinlik metriği %88.31'den %88.46'ya küçük bir artış göstermiştir. Hassasiyet metriği %86.08'den %87.34'e yükselirken, F1 skoru %87.18'den %87.90'a artış sağlamıştır. Özgüllük metriği ise %87.32 seviyesinde sabit kalmıştır. Bu sonuçlar, GridSearchCV'nin LR yöntemi için doğruluk, kesinlik, hassasiyet ve F1 skorunda iyileştirmeler sağladığını göstermektedir.

Şekil 3.2, NB yöntemi için GridSearchCV yöntemi uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerinin karşılaştırmasını görselleştirmektedir. GridSearchCV öncesi NB yöntemi için doğruluk %86 iken, GridSearchCV sonrası bu değer sabit kalmıştır. Hassasiyet metriği %89.19 seviyesinde sabit kalmış, hassasiyet metriği ise %83.54'te değişmemiştir. F1 skoru %86.27'de sabit kalırken, özgüllük metriği de %88.73 seviyesinde kalmıştır. Bu




**Şekil 3.1** LR yöntemine ait performans metriklerinin görselleştirilmesi



**Şekil 3.2** NB yöntemine ait performans metriklerinin görselleştirilmesi

sonuçlar, GridSearchCV'nin NB yöntemi üzerinde önemli bir etkisinin olmadığını göstermektedir.

Şekil 3.3, KNN yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerinin karşılaştırmalı sonuçlarını göstermektedir.

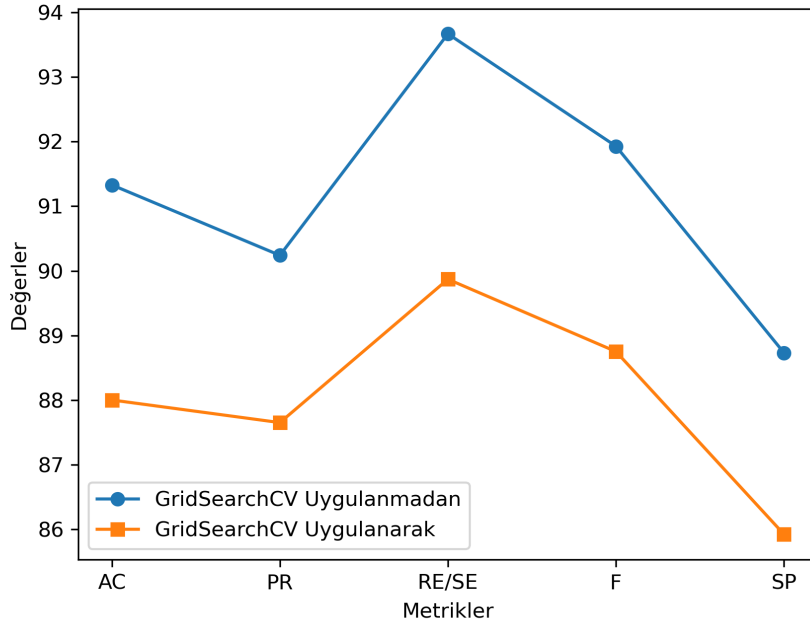


**Şekil 3.3** KNN yöntemine ait performans metriklerinin görselleştirilmesi


GridSearchCV uygulanmadan önce KNN yöntemi doğruluk metriğinde %90.67 değerine ulaşırken, GridSearchCV uygulandıktan sonra bu değer %91.33'e yükselmiştir. Kesinlik metriği %90.12'den %92.31'e, hassasiyet metriği %92.41'den %91.14'e düşerken, F1 skoru %91.25'ten %91.72'ye çıkmıştır. Özgüllük metriği ise %88.73'ten %91.55'e yükselmiştir. Bu bulgular, GridSearchCV'nin KNN yöntemi üzerinde çoğu performans metriğinde iyileşme sağladığını göstermekte, ancak hassasiyet metriğinde küçük bir düşüş olduğunu da ortaya koymaktadır.

Şekil 3.4, SVM yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak göstermektedir. GridSearchCV uygulanmadan önce SVM yöntemi doğruluk metriğinde %91.33 değerine ulaşırken, GridSearchCV uygulandıktan sonra bu değer %88'e düşmüştür. Kesinlik metriği %90.24'ten %87.65'e, hassasiyet metriği %93.67'den %89.87'ye gerilemiştir. F1 skoru %91.93'ten %88.75'e düşüş göstermiştir. Özgüllük metriği ise %88.73'ten %85.92'ye düşüş kaydetmiştir. Bu bulgular, GridSearchCV'nin SVM yönteminde performans metriklerinde azalmaya yol açtığını göstermektedir.

Şekil 3.5, SVM-RBF yöntemi için GridSearchCV yöntemi uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerinin karşılaştırmasını görselleştirmektedir. GridSearchCV öncesi SVM-RBF yöntemi için doğruluk %88 iken, GridSearchCV sonrası bu değer %88.67'ye yükselmiştir. Kesinlik

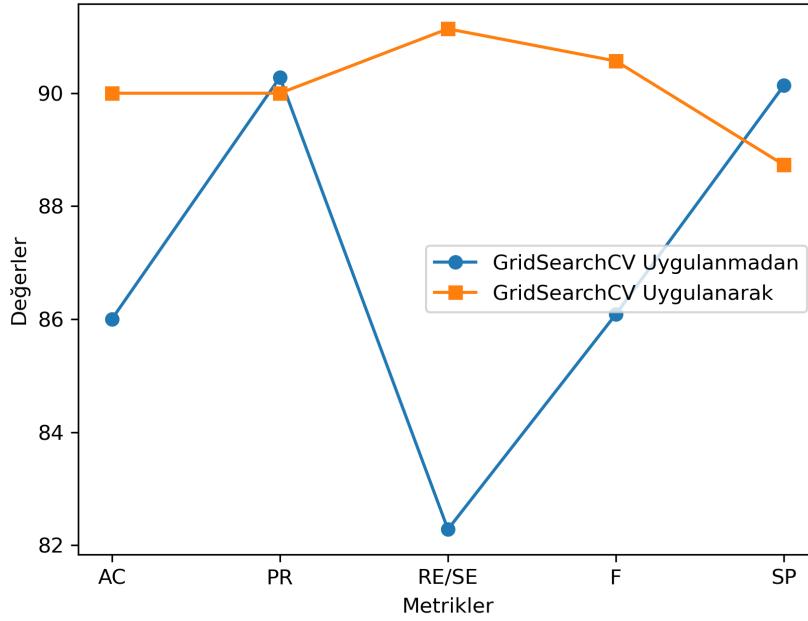


**Şekil 3.4** SVM yöntemine ait performans metriklerinin görselleştirilmesi



**Şekil 3.5** SVM-RBF yöntemine ait performans metriklerinin görselleştirilmesi

metriği %90.67'den %89.74'e düşmüş, hassasiyet metriği ise %86.08'den %88.61'e yükselmiştir. F1 skoru %88.31'den %89.17'ye çıkarken, özgüllük metriği %90.14'ten %88.73'e düşmüştür. Bu sonuçlar, GridSearchCV'nin SVM-RBF yöntemi için bazı metriklerde iyileşme sağladığını, ancak kesinlik ve özgüllük metriklerinde küçük düşüşler yaşandığını ortaya koymaktadır.




**Şekil 3.6** ANN yöntemine ait performans metriklerinin görselleştirilmesi


Şekil 3.6, ANN yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. GridSearchCV uygulanmadan önce ANN yöntemi için doğruluk %86 seviyesindeyken, GridSearchCV sonrası bu değer %90'a yükselmiştir. Kesinlik metriğinde %90.28'den %90 seviyesine küçük bir düşüş görülmüştür. Hassasiyet metriği %82.28'den %91.14'e yükselmiştir. F1 skoru %86.09'dan %90.57'ye artış göstermiştir. Özgüllük metriği ise %90.14'ten %88.73'e düşüş kaydetmiştir. Bu sonuçlar, ANN yönteminde GridSearchCV'nin doğruluk, hassasiyet ve F1 metriklerinde önemli iyileşmeler sağladığını, ancak kesinlik ve özgüllük metriklerinde küçük düşüslere neden olduğunu göstermektedir.

Şekil 3.7, DT yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. GridSearchCV uygulanmadan önce DT yöntemi için doğruluk %81.33 iken, GridSearchCV sonrası bu değer %84'e yükselmiştir. Kesinlik metriği %84'ten %92.31'e çıkmıştır. Hassasiyet metriği %79.75'ten %75.95'e düşmüştür. F1 skoru %81.82'den %83.33'e yükselmiş, özgüllük metriği ise %83.1'den %92.96'ya çıkarak dikkate değer bir artış göstermiştir. Bu sonuçlar, GridSearchCV'nin DT yöntemi için çoğu metrikte iyileştirme sağladığını, ancak hassasiyet metriğinde bir miktar düşüslere neden olduğunu ortaya koymaktadır.

Şekil 3.8, RF yöntemi için GridSearchCV uygulanmadan ve uygulandıktan



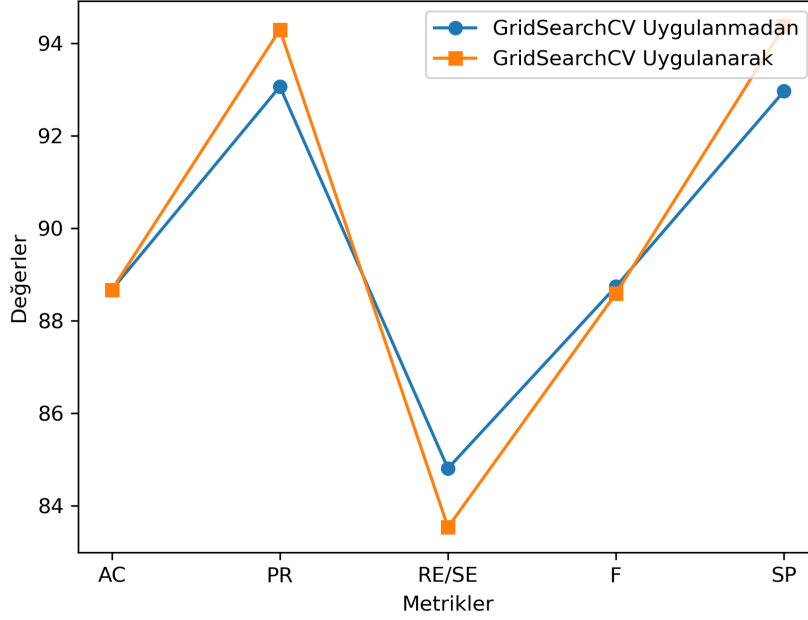
Şekil 3.7 DT yöntemine ait performans metriklerinin görselleştirilmesi



Şekil 3.8 RF yöntemine ait performans metriklerinin görselleştirilmesi

sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. GridSearchCV öncesinde RF yöntemi için doğruluk %90 iken, GridSearchCV sonrası bu değer %91.33'e yükselmiştir. Kesinlik metriği %93.24'ten %95.83'e yükselmiş, hassasiyet metriği %87.34 seviyesinde sabit kalırken, F1 skoru %90.2'den %91.39'a yükselmiştir. Özgüllük metriği ise %92.96'dan %95.77'ye

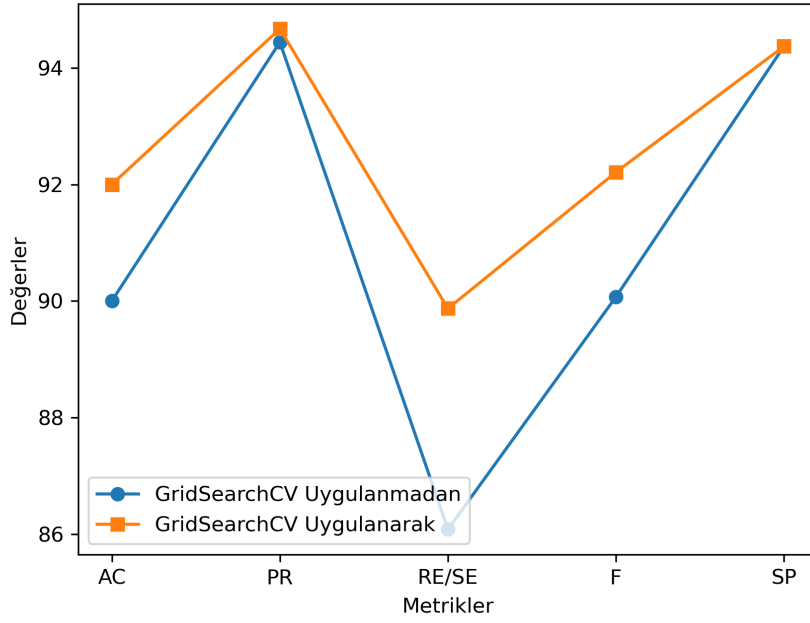
çıkarak önemli bir artış göstermiştir. Bu sonuçlar, GridSearchCV'nin RF yönteminde özellikle kesinlik ve özgüllük metriklerinde ciddi bir iyileşme sağladığını göstermektedir.



**Şekil 3.9** GB yöntemine ait performans metriklerinin görselleştirilmesi

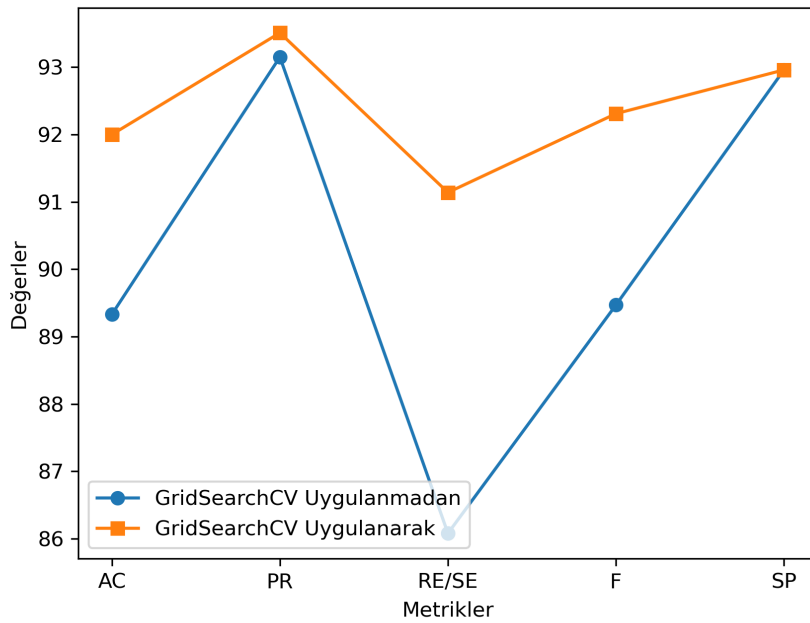
Şekil 3.9, GB yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. GB yöntemi için GridSearchCV öncesi doğruluk %88.67 iken, GridSearchCV sonrası bu değer sabit kalmıştır. Kesinlik metriği %93.06'dan %94.29'a yükselmiştir. Hassasiyet metriği %84.81'den %83.54'e düşerken, F1 skoru %88.74 seviyesinden %88.59'a küçük bir düşüş göstermiştir. Özgüllük metriği ise %92.96'dan %94.37'ye yükselmiştir. Bu sonuçlar, GB yönteminde kesinlik ve özgüllük metriklerinde iyileşme sağlandığını, ancak hassasiyet ve F1 skorunda küçük düşüşler yaşandığını göstermektedir.

Şekil 3.10, XGBoost yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. GridSearchCV uygulanmadan önce XGBoost yöntemi için doğruluk %90 seviyesindeyken, GridSearchCV sonrası bu değer %92'ye yükselmiştir. Kesinlik metriği %94.44'ten %94.67'ye hafif bir artış göstermiştir. Hassasiyet metriği %86.08'den %89.87'ye yükselmiştir. F1 skoru %90.07'den %92.21'e çıkarak iyileşme göstermiştir. Özgüllük metriği ise %94.37 seviyesinde sabit kalmıştır. Bu sonuçlar, XGBoost yönteminde GridSearchCV'nin doğruluk, hassasiyet ve F1 skorunda önemli iyileşmeler sağladığını, kesinlik metriğinde ise küçük bir artış



**Şekil 3.10** XGBoost yöntemine ait performans metriklerinin görselleştirilmesi

gözlemlendiğini ortaya koymaktadır.



**Şekil 3.11** CatBoost yöntemine ait performans metriklerinin görselleştirilmesi

Şekil 3.11, CatBoost yöntemi için GridSearchCV uygulanmadan ve uygulandıktan sonra elde edilen performans metriklerini karşılaştırmalı olarak sunmaktadır. CatBoost yöntemi için GridSearchCV öncesi doğruluk %89.33 iken, GridSearchCV

sonrası bu deęer %92'ye yükselmiştir. Kesinlik metrięi %93.15'ten %93.51'e küçük bir artış göstermiştir. Hassasiyet metrięi %86.08'den %91.14'e yükselmiştir. F1 skoru %89.47'den %92.31'e artmış, özgüllük metrięi ise %92.96 seviyesinde sabit kalmıştır. Bu sonuçlar, GridSearchCV'nin CatBoost yöntemi için doğruluk, hassasiyet ve F1 skorunda önemli iyileşmeler sağladığını ve özgüllük metrięinin sabit kaldığını göstermektedir.

GridSearchCV uygulanmadan önce, sınıflandırma modelleri arasında en yüksek doğruluk deęeri %91.33 ile SVM yöntemi tarafından elde edilmiştir. Ancak GridSearchCV uygulandıktan sonra, XGBoost ve CatBoost modellerinde doğruluk %92 seviyesine yükselmiştir. Bu durum, GridSearchCV'nin hiperparametre optimizasyonu sayesinde doğruluk metrięinde iyileştirme sağladığını ve performansın daha rekabetçi hale geldiğini göstermektedir. Özellikle CatBoost modelinde doğruluk deęerinin önemli bir artış gösterdiği ve SVM'in önceden sağladığı üstünlüğü paylaştığı gözlemlenmiştir. Bu sonuçlar, GridSearchCV'nin sınıflandırma performansını artırmada etkili bir araç olduğunu ortaya koymaktadır.

# 4

## SONUÇ

Bu bölümde, önerilen makine öğrenimi modellerinin kalp hastalığı veri setindeki performansı, literatürdeki diğer çalışmaların bulguları ile karşılaştırmalı olarak değerlendirilmektedir. Bu karşılaştırmalı analiz, mevcut çalışmada kullanılan yöntemlerin alternatif yaklaşımlara göre etkinliğini değerlendirmeyi ve önerilen modellerin üstün performans sergilediği alanları belirlemeyi amaçlamaktadır. Bu doğrudan karşılaştırma, GridSearchCV ile optimize edilmiş önerilen modellerin benzer veri setleri ve yöntemler kullanan çalışmalarla karşılaştırıldığında sağladığı gelişmelerin değerlendirilmesine olanak tanımaktadır.

**Tablo 4.1** Diğer makaleler ile sınıflandırma metriklerinin karşılaştırılması

MLA	AC(%)	PR(%)	RE/SE(%)	F(%)	SP(%)
[10] SVM	91.85	91	<b>96</b>	<b>93</b>	-
[1] LR	86.86	-	-	-	-
[9] SVM	85.86	-	-	-	-
XGBoost	<b>92</b>	<b>94.67</b>	89.87	92.21	<b>94.37</b>

Tablo 4.1, aynı veri kümesini kullanan üç farklı çalışmadan elde edilen en iyi sınıflandırma metriklerini, bu çalışmada önerilen modellerin sonuçları ile karşılaştırmalı olarak sunmaktadır. [10] çalışmasında, SVM yöntemi RBF çekirdeği ile %91.85 doğruluk oranına ve %96 hassasiyet değerine ulaşarak bu çalışmada yer alan en yüksek hassasiyet metriğini sağlamıştır. [1] ise LR yöntemiyle %86.86 doğruluk oranı bildirmiştir. [9] çalışmasında ise SVM yöntemi %85.86 doğruluk ile performans göstermiştir.

Bu çalışmada, GridSearchCV fonksiyonu kullanılarak yapılan hiperparametre optimizasyonu sonucunda XGBoost modeli %92 doğruluk, %94.67 kesinlik, %89.87 hassasiyet, %92.21 F1 skoru ve %94.37 özgüllük ile dengeli bir performans göstermiştir. Özellikle doğruluk ve kesinlik metriklerinde XGBoost, diğer çalışmalardaki sonuçların üzerine çıkmış ve yüksek performans sergilemiştir.

Bununla birlikte, hassasiyet metriđi aısından [10] alıřmasındaki SVM modelinin gerisinde kalmıřtır. Bu sonular, nerilen modelin genel dođruluk ve kesinlik aısından etkili bir yntem olduđunu, ancak hassasiyet metriđi zerinde daha fazla optimizasyon yapılabileceđini gstermektedir.

Bu bařarı, ncelikle eksik deđerlerin veri maniplasyonu ile ele alınması ve veri setinin standardizasyonu ile sađlanan tutarlılık ile mmkn olmuřtur. Ayrıca, GridSearchCV yntemi, CatBoost ynteminde de %92 dođruluk elde edilmesini sađlayarak nerilen modellerin performansını iyileřtirmiřtir.



- [1] V. Jain, “Heart Failure Prediction Using Machine Learning Algorithms with Cross Validations,” *2023 International Conference on Circuit Power and Computing Technologies*, ss. 1420–1423, 2023.
- [2] T. Ahmad, A. Munir, S. H. Bhatti, M. Aftab M. A. Raza, “Survival analysis of heart failure patients: A case study,” *PLOS ONE*, c. 12, no. 7, ss. 1–8, 2017.
- [3] P. Ponikowski, A. A. Voors, S. D. Anker et al., “2016 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: The Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC) Developed with the special contribution of the Heart Failure Association (HFA) of the ESC,” *European Heart Journal*, c. 37, no. 27, ss. 2129–2200, 2016.
- [4] H. Meshref, “Cardiovascular Disease Diagnosis: A Machine Learning Interpretation Approach,” *International Journal of Advanced Computer Science and Applications(IJACSA)*, c. 10, no. 12, 2019.
- [5] T. Wuest, D. Weimer, C. Irgens K.-D. Thoben, “Machine learning in manufacturing: advantages, challenges, and application,” *Production & Manufacturing Research*, c. 4, no. 1, ss. 23–45, 2016.
- [6] K. C. Santosh, N. Rasmussen, M. Mamun S. Aryal, “A systematic review on cough sound analysis for Covid-19 diagnosis and screening: is my cough sound COVID-19?” *PeerJ Comput Sci*, c. 8, e958, 2022.
- [7] M. Mamun, A. Farjana, M. A. Mamun M. S. Ahammed, “Heart failure survival prediction using machine learning algorithm: am I safe from heart failure?” *2022 IEEE World AI IoT Congress (AIIoT)*, IEEE, 2022, ss. 194–200.
- [8] M. M. Ahsan, S. A. Luna Z. Siddique, “Machine-Learning-Based Disease Diagnosis: A Comprehensive Review,” *Healthcare*, c. 10, no. 3, 2022.
- [9] C. D. Silva P. Kumarawadu, “Performance Analysis of Machine Learning Classification Algorithms in the Case of Heart Failure Prediction,” *2022 International Wireless Communications and Mobile Computing (IWCMC)*, IEEE, 2022, ss. 1160–1165.
- [10] H. V. R. Bindela, K. C. Yedubati, R. R. Gosula, E. Snir B. Rahmani, “Heart Failure Prediction Using Artificial Intelligence Methods,” *2023 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, IEEE, 2023, ss. 1–4.

- [11] S. Saravanan K. Swaminathan, “Hybrid K-Means and Support Vector Machine to Predict Heart Failure,” *2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, IEEE, 2021, ss. 1678–1683.
- [12] S. Zhang W. Zhou, “Prediction Model of Heart Failure Disease Based on GA-ELM,” *2021 40th Chinese Control Conference (CCC)*, IEEE, 2021, ss. 7944–7948.
- [13] V. Sharma, S. Yadav M. Gupta, “Heart Disease Prediction using Machine Learning Techniques,” *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)*, IEEE, 2020, ss. 177–181.
- [14] *Heart Failure Prediction Dataset*. erişim adresi: <https://www.kaggle.com/datasets/fedesoriano/heart-failure-prediction> (erişim tarihi 03/02/2025).
- [15] Y. Jin, H. Hou, M. Qin, W. Yang Z. Zhang, “Adaptive hypergraph regularized logistic regression model for bioinformatic selection and classification,” *Applied Intelligence*, c. 54, no. 3, ss. 2349–2360, Şub. 2024.
- [16] S. Dreiseitl L. Ohno-Machado, “Logistic regression and artificial neural network classification models: a methodology review,” *Journal of Biomedical Informatics*, c. 35, no. 5, ss. 352–359, 2002.
- [17] M. Saw, T. Saxena, S. Kaithwas, R. Yadav N. Lal, “Retracted: Estimation of Prediction for Getting Heart Disease Using Logistic Regression Model of Machine Learning,” *2020 International Conference on Computer Communication and Informatics (ICCCI)*, IEEE, 2020, ss. 1–6.
- [18] J. Wang, “Heart Failure Prediction with Machine Learning: A Comparative Study,” *Journal of Physics: Conference Series*, c. 2031, no. 1, s. 012 068, 2021.
- [19] I. Rish, “An empirical study of the naive Bayes classifier,” *IJCAI 2001 Work Empir Methods Artif Intell*, c. 3, 2001.
- [20] S. G. A, R. Prabha, M. Razmah, T. Veeramakali, S. S Y. R, “Machine Learning Heart Disease Prediction Using KNN and RTC Algorithm,” *2022 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*, 2022, ss. 1–5.
- [21] M. Gudadhe, K. Wankhade S. Dongre, “Decision support system for heart disease based on support vector machine and Artificial Neural Network,” *2010 International Conference on Computer and Communication Technology (ICCCT)*, IEEE, 2010, ss. 741–745.
- [22] B. Gnaneswar M. E. Jebarani, “A review on prediction and diagnosis of heart failure,” *2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)*, IEEE, 2017, ss. 1–3.
- [23] A. Bosch, A. Zisserman X. Munoz, “Image Classification using Random Forests and Ferns,” *2007 IEEE 11th International Conference on Computer Vision*, 2007, ss. 1–8.

- [24] S. M. Zaman, W. M. Qureshi, M. M. S. Raihan, A. B. Shams S. Sultana, "Survival Prediction of Heart Failure Patients using Stacked Ensemble Machine Learning Algorithm," *2021 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE)*, IEEE, 2021, ss. 117–120.
- [25] K. L. Kumar B. E. Reddy, "Heart Disease Detection System Using Gradient Boosting Technique," *2021 International Conference on Computing Sciences (ICCS)*, 2021, ss. 228–233.
- [26] A. Natekin A. Knoll, "Gradient boosting machines, a tutorial," *Frontiers in Neurorobotics*, c. 7, s. 21, 2013.
- [27] S. Sharma A. Singhal, "A Novel Heart Disease Prediction System Using XGBoost Classifier Coupled With ADASYN SMOTE," *2023 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, 2023, ss. 76–81.
- [28] K. Budholiya, S. K. Shrivastava V. Sharma, "An optimized XGBoost based diagnostic system for effective prediction of heart disease," *Journal of King Saud University - Computer and Information Sciences*, c. 34, no. 7, ss. 4514–4523, 2022.
- [29] X. Zhang ve diğ., "An accurate diagnosis of coronary heart disease by Catboost, with easily accessible data," *Journal of Physics: Conference Series*, c. 1955, no. 1, s. 012 027, 2021.
- [30] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush A. Gulin, "CatBoost: unbiased boosting with categorical features," *Advances in Neural Information Processing Systems*, c. 31, Curran Associates, Inc., 2018.
- [31] F. Ahmed, M. Saleem, Z. Rajpoot A. Noor, "Intelligent Heart Disease Prediction Using CatBoost Empowered with XAI," *International Journal of Computational and Information Science*, c. 2, no. 3, ss. 8–13, 2024.
- [32] C. B. Rjeily, G. Badr, A. H. A. Hassani E. Andres, "Predicting heart failure class using a sequence prediction algorithm," *2017 Fourth International Conference on Advances in Biomedical Engineering (ICABME)*, IEEE, 2017, ss. 1–4.
- [33] G. K. Sahoo, K. Kanike, S. K. Das P. Singh, "Machine Learning-Based Heart Disease Prediction: A Study for Home Personalized Care," *2022 IEEE 32nd International Workshop on Machine Learning for Signal Processing (MLSP)*, IEEE, 2022, ss. 1–6.
- [34] L. B. de Amorim, G. D. Cavalcanti R. M. Cruz, "The choice of scaling technique matters for classification performance," *Applied Soft Computing*, c. 133, s. 109 924, 2023.
- [35] A. Berdaly Z. Abdiakhmetova, "Predicting heart disease using machine learning algorithms," *Journal of Mathematics, Mechanics and Computer Science*, c. 115, no. 3, ss. 101–111, 2022.
- [36] F. Aldi, F. Hadi, N. A. Rahmi S. Defit, "Standardscaler's Potential in Enhancing Breast Cancer Accuracy Using Machine Learning," *Journal of Applied Engineering and Technological Science (JAETS)*, c. 5, ss. 401–413, Ara. 2023.

- [37] S. Gowriswari B. S, "Hyperparameters Optimization using Gridsearch Cross Validation Method for machine learning models in Predicting Diabetes Mellitus Risk," *2022 International Conference on Communication, Computing and Internet of Things (IC3IoT)*, 2022, ss. 1–4.
- [38] G. S. K. Ranjan, A. K. Verma S. Radhika, "K-Nearest Neighbors and Grid Search CV Based Real Time Fault Monitoring System for Industries," *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, IEEE, 2019, ss. 1–5.
- [39] G. N. Ahmad, H. Fatima, S. Ullah, A. S. Saidi Imdadullah, "Efficient Medical Diagnosis of Human Heart Diseases Using Machine Learning Techniques With and Without GridSearchCV," *IEEE Access*, c. 10, ss. 80 151–80 173, 2022.
- [40] B. K. Verma A. K. Yadav, "Advancing Software Vulnerability Scoring: A Statistical Approach with Machine Learning Techniques and GridSearchCV Parameter Tuning," *SN Computer Science*, c. 5, no. 5, s. 595, 2024.
- [41] K. Alemerien, S. Alsarayreh E. Altarawneh, "Diagnosing Cardiovascular Diseases using Optimized Machine Learning Algorithms with GridSearchCV," *Journal of Applied Data Sciences*, c. 5, no. 4, ss. 1539–1552, 2024.

## TEZDEN ÜRETİLMİŞ YAYINLAR

---

### **Konferans Bildirisi**

1. M. Karaçay, M. Akar, "Predicting Heart Disease using Machine Learning Algorithms", 9th International European Conference on Interdisciplinary Scientific Research, Valencia/Spain, pp. 246, January 19-21, 2024.

### **Proje**

1. Mutlu AKAR (Yürütücü), Mina KARAÇAY (Araştırmacı), "Makine Öğrenimi Tekniklerini Kullanarak Kalp Hastalığı Tahminleri", YTÜ-BAPK Yüksek Lisans Projesi, (07.08.2023-Devam Ediyor), (Proje No: FYL-2023-5865).