

Farklı Örnekleme Tekniklerine ve Farklı Sınıflandırıcılara Dayanarak Kalp Yetmezliği Tanılı Hastaların Sağkalımlarının İncelenmesi

A Study of Survival of Patients Diagnosed with Heart Failure Based on Different Sampling Techniques and Different Classifiers

^{ID} Rukiye Uzun Arslan¹, İrem Şenyar Yapıcı² ^{ID}

¹Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak
rukiyeuzun67@gmail.com, ORCID: 0000-0002-2082-8695

²Bilgisayar Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak
senyerirem@gmail.com, ORCID: 0000-0003-0655-340X

Öz

Kalp yetmezliği (KY), insanların yaşam kalitesini etkileyen ve ciddi komplikasyonlara yol açabilen bir sağlık sorunudur. Hastalığın karmaşıklığı ve bireysel faktörlerin çeşitliliği, hastaların sağkalımlarının tahminini oldukça zorlaştırmaktadır. Ancak günümüzde, KY tanılı hastaların sağkalımlarını tahmininde makine öğrenimine (MÖ) dayalı karar destek sistemleri önemli bir rol oynamaktadır. Bu sistemler, hastaların genetik profilleri, klinik özellikleri ve tedavi yanıtları gibi birçok bilgiyi birleştirerek daha doğru tahminler yapılmasına yardımcı olmaktadır. Gerçekleştirilen çalışmada, KY hastalarının sağkalımını öngörmek için MÖ temelli bir model önerilmiştir. Model korelasyon temelli özellik seçimine göre belirlenen anlamlı özelliklerle oluşturulmuş ve yedi farklı MÖ sınıflandırıcısının performansı, on üç farklı yeniden örnekleme tekniği kullanılarak değerlendirilmiştir. Modellerin performansını belirlemek adına 80:20 hold-out tekniği kullanılmış ve başarımları beş farklı performans metriğine göre değerlendirilmiştir. Yapılan analizlerde doğruluk metriği açısından en yüksek başarımlar %82 ile EditedNearestNeighbours az örnekleme tekniğinin uygulanması durumunda XGBoost algoritmasıyla elde edilmiştir. Bu bulgular, MÖ algoritmalarının yanı sıra örnekleme tekniklerinin de KY hastalarının sağkalım tahmininde kritik bir rol oynadığını vurgulamaktadır.

Anahtar Kelimeler – kalp yetmezliği, yeniden örnekleme teknikleri, sınıflandırma

Abstract

Heart failure (HF) is a health problem that affects people's quality of life and can lead to serious complications. The

complexity of the disease and the diversity of individual factors make the prediction of patient survival very difficult. However, nowadays, decision support systems based on machine learning (ML) play an important role in predicting the survival of patients with HF. These systems help to make more accurate predictions by combining many information such as genetic profiles, clinical characteristics and treatment responses of patients. In this study, a model based on ML is proposed to predict the survival of HF patients. The model is built with significant features determined by correlation-based feature selection and the performance of seven different ML classifiers is evaluated using thirteen different resampling techniques. The 80:20 hold-out technique is used to determine the performance of the models and their performance is evaluated according to five different performance metrics. In the analyses, the highest performance in terms of accuracy metric has been achieved with 82% with the XGBoost algorithm when the EditedNearestNeighbours undersampling technique was applied. These findings emphasize that besides ML algorithms, sampling techniques also play a critical role in HF patient survival prediction.

Keywords – heart failure, resample feature techniques, classifier

1. Giriş

Kalp yetmezliği (KY), kalbin vücuda yeterli miktarda kan pompalayamaması nedeniyle vücut işlevlerinde meydana gelen bozulmalarla karakterize edilen önemli bir sağlık sorunudur. KY, dünya genelinde en sık karşılaşılan morbidite ve mortalite nedenleri arasında yer almaktadır. Günümüzde, KY vakalarının dünya genelinde yaklaşık 64,34 milyon

olduğu ve bu sayının hızla arttığı bilinmektedir [1]-[3]. Ölüm oranları endişe verici olmasına rağmen KY vakalarının tamamı ölümle sonuçlanmamaktadır. KY vakalarında hastanın hayatta kalma olasılığını doğru bir şekilde tahmin edebilen belirli özellikler bulunmaktadır. Bu özellikler arasında serum sodyumu, ejeksiyon fraksiyonu, serum kreatinini, kan basıncı, yaş gibi faktörler yer almaktadır [3], [4].

KY geçiren hastalar genellikle olaydan sonraki birkaç gün boyunca hastanede gözlem altında tutulmakta ve sağlık durumları daha yakından takip edilmektedir. Bu süreçte, hastalardan düzenli kan örnekleri alınarak hematolojik parametrelerin yanı sıra yaş, cinsiyet, tütün kullanımı gibi hastaya ait bilgiler de değerlendirilmektedir. Ancak, bu verilerin analizi ve aralarındaki ilişkilerin belirlenmesi, hastaların iyileşme veya kötüleşme olasılığını tahmin etme zorluğunu beraberinde getirmektedir. Doğru sonuçlar elde etmek için analitik yöntemlerin ve modelleme tekniklerinin titizlikle uygulanması gerekmektedir. Bu çerçevede yararlanılan makine öğrenimi (MÖ) algoritmaları, kullanıcı verileri işleyerek sonuçları otomatik olarak öğrenmekte ve tahmin etmektedir. Yanı sıra farklı durumlara uyum sağlayabilmekte ve önceki öğrenmelerine dayanarak kararlar alabilmektedir. Bu algoritmalar, günümüzde sağlık sektöründe özellikle hastalık teşhisinde yaygın olarak kullanılmaktadır [5]. KY sonrası hastalardan alınan takip verilerinin analiz edilmesi, hastalığın mortalitesinin öngörülmesi açısından büyük önem taşımaktadır. Son yıllarda, sağlık sistemlerine entegre edilen MÖ algoritmaları KY tanısı ve prognoz değerlendirmesinde etkili bir çözüm sunmaktadır [3], [6], [7].

Chicco ve Jurman KY hastalarının olası sağlık durumlarını saptamak amacıyla 13 özellik içeren bir veri seti kullanarak farklı MÖ algoritmalarının başarımlarını değerlendirmişlerdir. Tüm özelliklerin kullanıldığı çalışmada Lojistik Regresyon (LR) algoritmasıyla en yüksek başarımlar elde edilmiştir [7]. Erdaş ve Ölçer KY hastalarının takip verilerini içeren bir veri seti üzerinde hastaların hayatta kalma tahmine yönelik MÖ temelli bir model önermişlerdir. Önerdikleri modelde beş farklı MÖ algoritmasının başarımları hem veri setindeki tüm özelliklere hem de korelasyon temelli öznelik seçim yöntemiyle çıkarılan özelliklere göre ayrı ayrı karşılaştırmışlardır. En yüksek başarımlar tüm özelliklerin kullanılması durumunda bir kural sınıflandırıcısıyla elde edilmiştir [8]. Başka bir çalışmada;

hastaların ameliyat öncesi ve ameliyat sırasındaki tıbbi verilerinden yararlanılarak ameliyat sonrası KY riskini tahmin etmeye yönelik Derin Piramit Evrişimli Sinir Ağları ve Aşırı Gradyan Artırma (XGBoost) yöntemleri içeren hibrid bir model önerilmiştir. Yapılan analizlerde önerilen modellerde daha yüksek başarımlar elde edilebileceği ortaya koyulmuştur [9]. Ishaq ve arkadaşları KY tanılı hastaların sağkalım durumlarının tespitinde dokuz farklı MÖ algoritmasının sınıflandırma başarımlarını araştırmışlardır. Analizlerde en yüksek sınıflandırma başarımlarını Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) uygulanan Ekstra Ağaç Sınıflandırıcısı (ETC) için elde edilmiştir [10]. Mansur Huang ve arkadaşları 13 özellik (semptom) içeren açık erişimli bir veri seti kullanarak KY'ni tahmin etmek için dört popüler MÖ algoritmasının performansını karşılaştırmıştır. Deneysel analizler sonucunda Rasgele Orman (RO)'nın en yüksek performans skorunu verdiği tespit edilmiştir. Yanı sıra KY tahmininde 13 semptomun tamamının önemli olduğu ortaya koyulmuştur [11]. Mamun ve arkadaşları KY ile ilişkili patofizyolojik parametrelerden hasta sağkalımını tahmin etmek için en önemli risk faktörlerine karşılık gelen özellikleri korelasyon matrisine göre tespit ederek, sekiz farklı MÖ algoritmasının performansları analiz etmişlerdir. Analizlerde LightGBM'nin diğer MÖ algoritmalarına kıyasla daha yüksek performansa sahip olduğu belirlenmiştir [12]. Muntasir Nishat ve arkadaşları hastaların KY'den kurtulma olasılıklarını tahmin etmek için üç farklı yaklaşım kullanarak 6 farklı MÖ algoritmasının performanslarını analiz etmişlerdir. İlk yaklaşımda veri seti üzerinde standart ve min-max ölçekleme yöntemlerini içeren bir veri ön işleme adımı uygulanmıştır. İkinci yaklaşımda algoritmaların hiperparametreleri optimize etmek adına ızgara arama çapraz doğrulama ve rastgele arama çapraz doğrulama teknikleri kullanılmıştır. Üçüncü yaklaşım olarak veri setine SMOTE ve düzenlenmiş en yakın komşu veri yeniden örnekleme tekniği (SMOTE-ENN) uygulanmıştır. Gerçekleştirilen analizlerde tüm yaklaşımlar için MÖ algoritmalarının performansları kapsamlı bir şekilde karşılaştırılmıştır. Yapılan karşılaştırmalar sonucunda, SMOTE-ENN ve standart ölçekleme tekniği birlikte uygulandığı durumda RO sınıflandırıcısının diğer tüm algoritmaları geride bıraktığı tespit edilmiştir [13]. Özbay ve Özbay açık erişimli dengesiz bir veri setine SMOTE tekniği uygulayarak, on farklı MÖ algoritmasının KY tahmin başarımlarını farklı performans metriklerine göre


kıyaslamışlardır. Tüm algoritmalar arasında en yüksek başarımlar bütün performans metrikleri açısından RO algoritmasıyla elde edilmiştir [14]. Sachdeva ve arkadaşları KY tanılı 299 hastanın tıbbi özelliklerini içeren bir veri seti üzerinden dört farklı MÖ algoritmasının hastaların hayatta kalma olasılıklarını tahminindeki başarımlarını analiz etmişlerdir. Yapılan analizlerle destek vektör makinesi (DVM) kullanılması durumunda en yüksek başarıma ulaşabileceği ortaya konulmuştur [15]. Mudassar ve arkadaşları tarafından dengesiz bir veri seti üzerinde SMOTE tekniği uygulanarak dokuz farklı MÖ algoritmasının başarımları çeşitli performans metrikleri açısından değerlendirilmiştir. 10-kat çapraz doğrulama ve %70-%30 hold-out tekniğiyle eğitilen modelde en yüksek performans SMOTE uygulanma durumuna bakılmaksızın LightBoost algoritması için elde edilmiştir [16]. Keser ve Keskin gerçek bir veri seti kullanarak KY tanılı hastaların sağ kalımlarının tahmininde üç farklı MÖ algoritmasının performanslarını karşılaştırmıştır [17]. 2024 yılında yapılan bir çalışmada KY tahmininde farklı kategorilerde yer alan çeşitli MÖ algoritmalarının performansları hem kategorik hem de genel performans bakımından irdelenmiştir [5]. Yapıcı ve arkadaşları tarafından yapılan çalışmada SMOTE tekniğinin uygulanma durumuna göre KY teşhisinde farklı MÖ algoritmalarının başarımları iki farklı çapraz doğrulama tekniği kullanarak karşılaştırılmıştır [3].

Yukarıda değinilen çalışmalar, KY tanılı hastaların sağkalımlarının tahmininde MÖ temelli karar destek sistemlerinin etkili bir şekilde kullanılabileceğini göstermektedir. Ancak bu sistemlerde kullanılan MÖ algoritmalarının hangisinin başarımının daha yüksek olduğu hususunda kesin bir sonuca varılamamıştır. Bu doğrultuda, gerçekleştirilen çalışmada KY tanılı hastaların sağkalımlarını belirlemeye yönelik MÖ temelli üç aşamalı hibrit bir model önerilmiştir. Çalışmanın ilk aşamasında korelasyon temelli bir özellik seçim yöntemi kullanılarak veri setindeki belirleyici özellikler tespit edilmiştir. İkinci aşamada bu özellikler kullanılarak yedi farklı MÖ algoritmasına dayanan modelin performansları analiz edilmiştir. Üçüncü aşama da ise modellerin başarımlarını arttırmak adına eğitim veri seti üzerinde 13 farklı yeniden örnekleme tekniği uygulamanın etkileri analiz edilmiştir. Çalışmada modellerin doğruluğu hold-out (80:20) tekniğine göre değerlendirilirken, modellerin performansları yeniden örnekleme tekniğinin uygulanıp uygulanmama durumları için test verisi üzerinden

hesaplanan beş farklı metriğe (doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC gibi) göre karşılaştırılmıştır.

2. Materyal ve Metotlar

KY tanılı hastaların hayatta kalma durumlarını belirlemek için önerilen modelin blok diyagramı Şekil 1'de gösterilmiş olup bu bölümde uygulanan yöntemler anlatılmıştır.



Şekil 1. Önerilen modelin akış diyagramı.

2.1 Veri Seti

Bu çalışmada, 299 tane KY tanılı hastanın tıbbi kayıtlarını içeren açık erişimli bir veri seti kullanılmıştır. Veri seti sınıf değişkenleri de dahil olmak üzere 13 özelliği içermekte olup, Ahmad ve arkadaşları tarafından Pakistan'ın Pencap eyaletindeki Faisalabad Kardiyoloji Enstitüsü Hastanesi'nden toplanmıştır. Tablo 1'de veri seti hakkında ayrıntılı açıklama sunulmuştur [4].

Veri seti, hastaların yaşları, tütün kullanımı, çeşitli kan tahlili sonuçları ile diyabet, tansiyon ve anemi gibi hastalıklara dair bilgileri içermektedir. Kreatinin fosfokinaz, trombosit, ejiksiyon fraksiyonu, kreatinin ve sodyum gibi değerler sürekli değişkenlerken; sigara kullanımı, diyabet, anemi, kan basıncı ve cinsiyet gibi bilgiler kategorik değişkenler olarak tanımlanmıştır. Hastaların sağkalım süreleri gün cinsinden belirtilmiştir. Veri setinde eksik değer olmamakla birlikte 130 günlük ortalama takip sürecinde hastaların 96'sı hayatını kaybetmiştir. Bu durum veri setinin dengesiz bir dağılıma sahip olduğunu göstermektedir. Bununla birlikte veri setinde ölüm Olayı=1 hayatını kaybeden hastayı, ölüm olayı=0 ise hayatta kalan hastayı ifade etmektedir. Bu çalışmada KY tanılı hastaların sağ

kalımlarının tahmininde MÖ sınıflandırıcıları ile birlikte yeniden örnekleme tekniklerinin birlikte kullanılması durumunda sınıflandırıcı performansları irdelenmiştir.

2.2 Veri Ön işleme

MÖ dayalı modellerin performansları kullanılan verilerin kalitesiyle yakından ilintilidir. Bu nedenle modellerde, veri ön işleme süreci büyük önem arz etmektedir. Veri ön işleme süreci; verilerin dönüştürülmesini, yeniden örnekleme yapılmasını ve özellik seçiminin uygulanmasını içermekte olup, aynı zamanda bozuk veya eksik veri noktalarını ve aykırı değerleri tespit ederek verilerin temizlenmesini sağlamaktadır. Bu kapsamda çalışmada ilk olarak veri setinde kategorik formatta olan özelliklerin değerleri tam sayı formatına dönüştürülmüş ve ardından min-max yöntemi uygulanarak veriler normalize edilmiştir. Daha sonra korelasyon temelli bir özellik seçim yöntemi olan CfsSubsetEval algoritmasıyla en iyi ilk arama yöntemine dayanarak veri setindeki anlamlı (belirleyici) özellikler tespit edilmiştir. Buna göre veri setindeki en anlamlı özellikler yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre olarak belirlenmiştir.

2.3 Yeniden Örnekleme Teknikleri

Gerçek veri setlerinde sınıf dağılımlarının dengesiz olduğu durumlar oldukça yaygındır. Bu dengesizlik, çoğu zaman bazı sınıfların diğerlerine kıyasla daha fazla veya daha

az örneğe sahip olması durumunda ortaya çıkmaktadır. Dengesiz veri problemi, bu tür veri setlerinde modellerin sınıflandırma performansını olumsuz yönde etkileyebilmektedir. Özellikle çoğunluk sınıfının daha fazla örneğe sahip olması, azınlık sınıfının doğru bir şekilde öğrenilmesini zorlaştırabilmektedir. Bu durum, geleneksel sınıflandırma modellerinin azınlık sınıfını ihmal etmesine veya yanlış sınıflandırmasına yol açabilmektedir. Sonuç olarak, dengesiz veri setleriyle çalışırken, sınıflandırıcıların performans ölçütleri (doğruluk, hassasiyet, geri çağırma gibi) olumsuz etkilenebilmektedir. Dengesiz veri probleminin üstesinden gelmek adına literatürde birçok yaklaşım geliştirilmiştir. Bu yaklaşımlardan biri olan örnekleme tabanlı yaklaşım, azınlık sınıftaki örnekleri artırarak (aşırı örnekleme, oversampling) veya çoğunluk sınıftaki örnekleri azaltarak (az örnekleme, undersampling) sınıf dengesizliğini azaltmayı ve dolayısıyla sınıflandırma performansını iyileştirmeyi amaçlamaktadır [18], [19]. Gerçekleştirilen bu çalışmada veri setindeki dengesizliği gidermek ve böylece sınıflandırıcıların performanslarını artırmak amacıyla on üç farklı yeniden örnekleme tekniğinden yararlanılmıştır.

Tablo 1. Veri setindeki özelliklerinin genel bir tanımı [3]

Özellik	Tanımı ve Aralığı
Yaş	Hastanın yaşı (Yıl)
Cinsiyet	Hastanın cinsiyet bilgisi (Kategorik)
Tütün kullanımı	Hastanın tütün kullanma durumu (Kategorik)
Anemi	Sağlıklı kırmızı kan hücrelerinin eksikliği (Kategorik)
Yüksek kan basıncı	Hastanın kan basıncı durumu (Kategorik)
Kreatinin Fosfokinaz (CPK)	Kandaki Kreatinin Fosfokinaz enzimi miktarı (mcg/L)
Diyabet	Hastanın diyabetik durumu (Kategorik)
Ejeksiyon Fraksiyonu	Kalp kasılırken kalpten çıkan kan miktarı (%)
Trombositler	Kandaki trombosit sayısı (kiloplateletler/mL)
Serum Kreatinin	Kandaki kreatinin düzeyi (mg/dL)
Serum Sodyum	Kandaki sodyum seviyesi (mEq/L)
Zaman	Takip süresi (Gün)
(Hedef) Ölüm Olayı	Takip süresi boyunca hayatta kalan hasta sayısı (Kategorik)

2.4. Sınıflandırıcılar

Sınıflandırma problemlerinde, veri setindeki desenler ve ilişkiler üzerinden öğrenilen bilgiler kullanılarak, yeni gelen

veri noktalarının hangi sınıfa ait olduğu belirlenmektedir. Bu tür problemlerde, veri noktalarının hangi kategorilere ait olduğunu belirlemek için farklı yöntemler kullanılabilir. Bu yöntemler, veri setinin özelliklerine, problem alanına ve gereksinimlere bağlı olarak değişiklik göstermektedir. Sınıflandırma problemlerinde önemli olan, uygun bir sınıflandırma algoritması seçmek ve modelin doğruluğunu değerlendirmek için uygun metrikleri kullanmaktır. Gerçekleştirilen bu çalışma kapsamında KY tanılı hastaların sağkalımlarının tahmini için literatürde sıklıkla tercih edilen RO, DVM, Gradyan artırma (Gradient Boosting, GB), XGBoost, LightGBM, Adaptif Arttırma

(AdaBoost, Adaptive Boosting) ve ETC algoritmaları kullanılmıştır. Kullanılan sınıflandırıcı algoritmaları Tablo 2’de açıklanmıştır.

2.5 Model Doğrulama ve Performans Değerlendirme Kriterleri

Çapraz doğrulama, istatistiksel analiz sonuçlarının bağımsız bir veri kümesinde ne ölçüde genelleştirildiğini değerlendirmek için uygulanan bir model doğrulama tekniğidir. Bu çalışmada veri setini rastgele eğitim seti (%80) ve test seti (%20) olarak ayıran hold-out yöntemi kullanılarak modellerin doğruluğu değerlendirilmiştir. Yeniden

Tablo 2. Kullanılan sınıflandırma algoritmaları

Algoritma	Tanımı
RO	RO, birden fazla zayıf öğrenenin bir araya gelerek doğru tahminler ürettiği ağaç tabanlı bir topluluk öğrenme modelidir. Bu model, torbalama tekniği kullanılarak çeşitli önyükleme örnekleriyle çeşitli karar ağaçlarını eğitmek için kullanılmaktadır. Her bir ağaç, örneğin boyutunun eğitim veri kümesine eşit olduğu, ancak eğitim veri kümesinden rastgele örnekleme yapılarak türetilen bir önyükleme örneğiyle eğitilmektedir. Bu şekilde, her bir ağaç farklı bir alt örneklemeyle eğitilmekte ve topluluk olarak bir araya getirilmektedir. Böylece daha güçlü ve genelleştirilebilir bir sınıflandırıcı elde edilmektedir [3].
DVM	DVM, veriler arasında bir ayrım yapmak için karar düzlemleri olarak adlandırılan yüksek boyutlu hiperdüzlemler oluşturmaktadır. Bu hiperdüzlemler, farklı sınıflara ait verileri birbirinden ayırmak için en iyi şekilde yerleştirilmektedir. Temel prensibi, veri noktalarını en iyi şekilde sınıflandıran bir hiperdüzlemi bulmaktır. Bu hiperdüzlem, veri noktalarının en yakınları arasındaki mesafeyi maksimize etmeye çalışmaktadır, böylece sınıflar arasındaki marjı maksimize etmektedir [20].
GB	GB, birçok zayıf sınıflandırıcının bir araya gelerek güçlü bir öğrenme modeli oluşturduğu bir topluluk öğrenme algoritmasıdır. Genellikle karar ağacı prensibiyle çalışır ve her bir bağımsız ağacı yaratırken maliyetli ve zaman alıcı bir seçim yapmaktadır. Algoritma, bir dizi ince ayarın ardından zayıf öğrenme algoritmalarını geliştirerek gücünü artırmaktadır. Yaklaşık olarak doğru öğrenme olasılığı adı verilen özelliğe dayanan GB, işlenmemiş veriler üzerinde iyi çalışırken, veri eksik değerlerini verimli bir şekilde ele almaktadır [21].
XGBoost	XGBoost, optimize edilen bir kayıp fonksiyonu ve çeşitli düzenlemelerle desteklenen yüksek performanslı bir güçlendirme tekniğidir. GB algoritmasıyla çalışan XGBoost, modelin zor durumlara odaklanmasını sağlamakta ve bu durumları önceki modellerden daha iyi ele almasını sağlamaktadır. Bu, gözlemlerin dağılımını çarpıtarak zor örnekleri daha fazla vurgulayarak gerçekleştirilmektedir. Böylece, her bir zayıf öğrenen model daha iyi performans göstermekte ve sonunda tüm bu modeller birleştirilerek güçlü bir tahminci elde edilmektedir [22].
LightGBM	LightGBM, GB’e dayanan yüksek performanslı ve dağıtılmış bir MÖ algoritmasıdır. Bu algoritma, özellikle büyük veri kümeleriyle çalışırken hızlı eğitim süreleri ve yüksek tahmin doğruluğu sağlamaktadır. LightGBM, ağaç tabanlı bir model oluştururken, diğer GB modellerine kıyasla daha hızlı eğitim süreleri sunmaktadır. Bu, büyük veri kümeleri veya yüksek boyutlu özelliklerle çalışırken avantajlıdır. LightGBM ayrıca bellek kullanımını optimize etmekte ve özelleştirilmiş kayıp fonksiyonları ve metrikler kullanarak modelin performansını artırma esnekliği sunmaktadır. Bu nedenle, birçok MÖ uygulamasında tercih edilmektedir [23].
AdaBoost	AdaBoost, genellikle diğer algoritmalarla birlikte kullanılarak performansını artırmak için tercih edilen bir algoritmadır. Zayıf öğrencileri güçlü öğrencilere dönüştürmek için güçlendirme (boosting) üzerinde çalışmaktadır.

	Her ağaç, AdaBoost sınıflandırıcısında önceki ağaçların hata oranına bağlı olarak oluşturulmaktadır. Bu şekilde, hatalı sınıflandırılan örnekler daha fazla vurgulanmakta ve yeni eklenen ağaçlar bu hatalara odaklanmaktadır, böylece daha doğru bir sınıflandırıcı elde edilmektedir [24].
ETC	ETC, çalışma prensibi bakımından RO'a oldukça benzeyen bir çalışma prensibine sahiptir, ancak ağaçların inşaa yöntemi açısından farklılık göstermektedir. Her bir KA, orijinal eğitim veri örneklerinden oluşturulmaktadır. Karar vermek için en iyi k özelliğin rastgele örneklere uygulandığı ve Gini indeksinin kullanıldığı en üst özellik seçilmektedir. Bu rastgele örnek özellikler, korelasyonsuz birçok KA'nın oluşturulmasını sağlamaktadır. Bu sayede, daha genel ve çeşitli bir modele olanak tanımaktadır [25].

örnekleme yöntemlerinin sadece eğitim setine uygulandığı çalışmada modellerin performansları test verisi üzerinden karmaşıklık matrisinden hesaplanan dört farklı metriğe göre değerlendirilmiştir. Karmaşıklık matrisi gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi göstermektedir. Genellikle dört ana kategoriden oluşmaktadır: Doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN). Bu kategoriler, modelin sınıfları ne kadar doğru tahmin ettiğini ve ne kadar hata yaptığını göstermektedir [26]. Eğer veri tıbbi bir uygulamayla ilişkilendirilmişse, yanlış negatif tahminler en kritik olanlardır çünkü hastalığı kaçırmak veya yanlış teşhis koymak ciddi sonuçlara yol açabilmektedir.

Karmaşıklık matrisinden hesaplanan performans metrikleri Tablo 3'de kısaca açıklanmıştır. Çalışmada modellerin performansları Tablo 3'de verilen metriklerin

haricince ROC eğrisinin altında kalan alan (AUC) metriği kullanılarak da değerlendirilmiştir. AUC-ROC eğrisi metriği, farklı sınıflandırma eşiklerindeki duyarlılık ve özgüllük değerlerini görselleştirerek sınıflandırıcının performansını geniş bir perspektiften değerlendirmektedir. Böylelikle, sınıflandırıcıların farklı veri kümesi veya koşullar altında nasıl performans göstereceği hakkında kapsamlı bir bilgi sağlamaktadır. Bu bağlamda çalışma kapsamında modellerin performanslarını daha geniş bir açıdan değerlendirmek adına AUC-ROC eğrisi metriği de göz önünde bulundurulmuştur.

3. Deneysel Sonuçlar

Bu çalışmada açık erişime sahip gerçek bir veri seti kullanılarak, KY tanılı hastaların sağ kalımlarının tahmini için

Tablo 3. Performans metrikleri.

Metrik Adı	Formülü	Tanımı
Doğruluk	$\frac{DP + DN}{DP + DN + YP + YN}$	Doğruluk, bir modelin doğru tahmin ettiği örneklerin oranını ifade etmektedir.
Duyarlılık	$\frac{DP}{YN + DP}$	Duyarlılık, gerçek pozitiflerin tüm pozitif örnekler içindeki oranını ifade etmekte ve modelin gerçek pozitifleri ne kadar iyi tanıdığını ölçmektedir.
Kesinlik	$\frac{DP}{YP + DP}$	Kesinlik, doğru pozitiflerin toplam pozitif tahminlere oranını ifade etmekte olup, modelin doğru pozitif tahminlerinin ne kadarını doğru bir şekilde gerçek pozitif olarak belirlediğini göstermektedir.
F-Skor	$\frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}}$	F-skor kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır.
AUC-ROC	$\int DPR \cdot d(YPR)$	ROC eğrisinin altında kalan alanı ifade etmekle birlikte; doğru pozitif oranının (DPR) yanlış pozitif oranının (FPR) fonksiyonu olarak tanımlanmaktadır.

CfsSubsetEval algoritmasıyla veri setindeki belirleyici olan özellikler (yaş, ejeksiyon fraksiyonu, serum kreatinin, serum sodyum ve süre) tespit edilmiştir. İkinci aşamada bu özellikleri kullanan yedi farklı MÖ algoritmasına dayanan (RO, AdaBoost, XGBoost, LightGBM, DVM, GB ve ETC) modeller oluşturularak başarımları karşılaştırılmıştır. Üçüncü

aşamada ise modellerin performanslarını iyileştirmek amacıyla on üç farklı yeniden örnekleme yönteminin uygulanmasının etkileri analiz edilmiştir. Çalışmada kullanılan algoritmaların parametreleri Spyder programının kendi varsayılan değerleri olacak şekilde bırakılmış, model başarımına olumlu ya da olumsuz etki edebilecek

değişikliklerden kaçınılmıştır. Ayrıca modellerin doğruluğu için 80:20 hold-out tekniği kullanılırken, performansları yeniden örnekleme tekniklerinin uygulanıp uygulanmama durumları için test verisi üzerinden hesaplanan beş farklı

parametreye (doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC) göre değerlendirilmiştir. Buna göre RO, Adaboost, XGBoost, LightGBM, DVM, GB ve ETC için elde edilen sonuçlar sırasıyla Tablo 4'den Tablo 10'a kadar sunulmuştur.

Tablo 4. RO algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,59	0,68	0,52	0,70	0,83
Fazla Örnekleme	SMOTE	0,68	0,68	0,68	0,73	0,84
	RandomOverSampler	0,64	0,74	0,56	0,73	0,84
	ADASYN	0,67	0,75	0,60	0,75	0,86
	Bonderlinesmote	0,67	0,75	0,60	0,75	0,84
	SVMSMOTE	0,67	0,70	0,64	0,73	0,80
Az Örnekleme	EditedNearestNeighbours	0,74	0,69	0,80	0,77	0,85
	AIKNN	0,74	0,69	0,80	0,77	0,86
	InstanceHardnessThreshold	0,72	0,61	0,88	0,72	0,87
	NearMiss	0,65	0,67	0,64	0,72	0,85
	NeighbourhoodCleaningRule	0,73	0,67	0,80	0,75	0,85
	OneSidedSelection	0,65	0,71	0,60	0,73	0,85
	RandomUnderSampler	0,72	0,72	0,72	0,77	0,84
	TomekLinks	0,65	0,71	0,60	0,73	0,86

Tablo 5. Adaboost algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,59	0,75	0,48	0,72	0,84
Fazla Örnekleme	SMOTE	0,70	0,83	0,60	0,78	0,86
	RandomOverSampler	0,70	0,83	0,60	0,78	0,87
	ADASYN	0,73	0,84	0,64	0,80	0,79
	Bonderlinesmote	0,67	0,75	0,6	0,75	0,84
	SVMSMOTE	0,71	0,80	0,64	0,78	0,80
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,88
	AIKNN	0,75	0,71	0,80	0,78	0,86
	InstanceHardnessThreshold	0,73	0,63	0,88	0,73	0,86
	NearMiss	0,64	0,68	0,60	0,72	0,83
	NeighbourhoodCleaningRule	0,73	0,70	0,76	0,77	0,83
	OneSidedSelection	0,71	0,88	0,60	0,80	0,87
	RandomUnderSampler	0,68	0,73	0,64	0,75	0,86
	TomekLinks	0,70	0,83	0,60	0,78	0,87

Tablo 6. XGBoost algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemesiz	-	0,68	0,79	0,60	0,77	0,86
Fazla Örnekleme	SMOTE	0,72	0,77	0,68	0,78	0,87
	RandomOverSampler	0,71	0,80	0,64	0,78	0,88
	ADASYN	0,67	0,82	0,56	0,77	0,85
	Bonderlinesmote	0,74	0,81	0,68	0,80	0,85
	SVMSMOTE	0,72	0,77	0,68	0,78	0,83
Az Örnekleme	EditedNearestNeighbours	0,78	0,77	0,80	0,82	0,88
	AIKNN	0,73	0,70	0,76	0,77	0,87
	InstanceHardnessThreshold	0,75	0,64	0,92	0,75	0,88
	NearMiss	0,73	0,70	0,76	0,77	0,85
	NeighbourhoodCleaningRule	0,72	0,68	0,76	0,75	0,86
	OneSidedSelection	0,70	0,83	0,60	0,78	0,88
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,89
	TomekLinks	0,63	0,81	0,52	0,75	0,87

Tablo 7. LightGBM algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemez	-	0,68	0,88	0,56	0,78	0,88
Fazla Örnekleme	SMOTE	0,65	0,71	0,60	0,73	0,87
	RandomOverSampler	0,63	0,81	0,52	0,75	0,88
	ADASYN	0,68	0,79	0,60	0,77	0,87
	Bonderlinesmote	0,68	0,79	0,60	0,77	0,84
	SVMSMOTE	0,75	0,78	0,72	0,80	0,82
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,87
	AIKNN	0,73	0,70	0,76	0,77	0,88
	InstanceHardnessThreshold	0,74	0,62	0,92	0,73	0,87
	NearMiss	0,72	0,72	0,72	0,77	0,86
	NeighbourhoodCleaningRule	0,78	0,79	0,76	0,82	0,85
	OneSidedSelection	0,73	0,94	0,60	0,82	0,86
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,86
	TomekLinks	0,67	0,82	0,56	0,77	0,88

Tablo 8. DVM algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemez	-	0,65	0,78	0,56	0,75	0,82
Fazla Örnekleme	SMOTE	0,71	0,74	0,68	0,77	0,82
	RandomOverSampler	0,71	0,69	0,72	0,75	0,81
	ADASYN	0,75	0,73	0,76	0,78	0,83
	Bonderlinesmote	0,76	0,76	0,76	0,80	0,83
	SVMSMOTE	0,75	0,78	0,72	0,80	0,80
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,83
	AIKNN	0,71	0,69	0,72	0,75	0,83
	InstanceHardnessThreshold	0,76	0,70	0,84	0,78	0,84
	NearMiss	0,69	0,71	0,68	0,75	0,85
	NeighbourhoodCleaningRule	0,72	0,72	0,72	0,77	0,83
	OneSidedSelection	0,67	0,75	0,60	0,75	0,83
	RandomUnderSampler	0,75	0,73	0,76	0,78	0,81
	TomekLinks	0,67	0,75	0,60	0,75	0,82

Tablo 9. GB algoritması için performans metrikleri.

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemez	-	0,54	0,83	0,40	0,72	0,86
Fazla Örnekleme	SMOTE	0,67	0,82	0,56	0,77	0,87
	RandomOverSampler	0,67	0,82	0,56	0,77	0,88
	ADASYN	0,62	0,76	0,52	0,73	0,86
	Bonderlinesmote	0,67	0,93	0,52	0,78	0,85
	SVMSMOTE	0,68	0,88	0,56	0,78	0,81
Az Örnekleme	EditedNearestNeighbours	0,72	0,72	0,72	0,77	0,87
	AIKNN	0,70	0,66	0,76	0,73	0,87
	InstanceHardnessThreshold	0,71	0,62	0,84	0,72	0,85
	NearMiss	0,63	0,65	0,60	0,70	0,84
	NeighbourhoodCleaningRule	0,71	0,69	0,72	0,75	0,85
	OneSidedSelection	0,71	0,88	0,60	0,80	0,86
	RandomUnderSampler	0,73	0,75	0,72	0,78	0,88
	TomekLinks	0,67	0,93	0,52	0,78	0,88

Tablo 10. ETC algoritması için performans metrikleri

Örnekleme	Kullanılan Teknik	F1 Skoru	Duyarlılık	Kesinlik	Doğruluk	AUC
Örneklemez	-	0,65	0,78	0,56	0,75	0,88
Fazla Örnekleme	SMOTE	0,67	0,75	0,60	0,75	0,87
	RandomOverSampler	0,67	0,93	0,52	0,78	0,86
	ADASYN	0,68	0,73	0,64	0,75	0,85
	Bonderlinesmote	0,68	0,73	0,64	0,75	0,88
	SVMSMOTE	0,65	0,71	0,60	0,73	0,83
Az Örnekleme	EditedNearestNeighbours	0,75	0,73	0,76	0,78	0,87
	AIKNN	0,75	0,73	0,76	0,78	0,86
	InstanceHardnessThreshold	0,78	0,72	0,84	0,80	0,87
	NearMiss	0,64	0,68	0,60	0,72	0,87
	NeighbourhoodCleaningRule	0,69	0,71	0,68	0,75	0,86
	OneSidedSelection	0,70	0,83	0,60	0,78	0,86
	RandomUnderSampler	0,73	0,75	0,72	0,78	0,86
	TomekLinks	0,70	0,83	0,60	0,78	0,87

Elde edilen sonuçlar incelendiğinde, bazı yeniden örnekleme yöntemlerinin belirli sınıflandırıcıların başarısını, örnekleme yapılmayan duruma kıyasla azalttığı gözlemlenmiştir. XGboost algoritmasını kullanarak yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %77 iken, InstanceHardnessThreshold, NeighbourhoodCleaningRule ve TomekLinks gibi az örnekleme yöntemlerinin uygulanmasıyla bu başarı oranı %75'e düşmüştür. LightGBM algoritmasıyla yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %78 iken, bu değer SMOTE ve InstanceHardnessThreshold yöntemlerinin uygulanmasıyla %73'e, RandomOverSampler yönteminin uygulanmasıyla %75'e ve son olarak ADASYN, Bonderlinesmote, EditedNearestNeighbours, AIKNN, NearMiss ve TomekLinks yöntemlerinin uygulanmasıyla %77'ye düşmüştür. GB algoritması kullanılarak yapılan sınıflandırmalarda, örnekleme yapılmayan durumda başarı oranı %72 iken, algoritmaya NearMiss örnekleme yöntemi uygulanması durumunda başarı oranı %70'e inmiştir. ETC algoritmasıyla yapılan sınıflandırmalar için ise örnekleme yapılmayan durumda %75 olan başarı oranı SVMSMOTE örnekleme yöntemi uygulanması durumunda %73 ve NearMiss örnekleme yöntemi uygulanması durumunda ise %72'ye düşmüştür. Elde edilen sonuçlar genel olarak irdelendiğinde, yeniden örnekleme tekniklerinin genel anlamda sınıflandırma başarısını artırdığı tespit edilmiştir.

Sınıflandırma başarımı açısından bakıldığında, yeniden örnekleme tekniklerinin kullanılmasıyla RO algoritmasında %10'luk, LightGBM algoritmasında %4'lük, XGboost, DVM

ve ETC algoritmalarında %7'lik ve Adaboost ile GB algoritmalarında %12'lik bir performans artışı elde edilmiştir. Örnekleme tekniklerinin başarı durumları değişkenlik gösterse de, bu çalışmada az örneklemenin daha başarılı sonuçlar verdiği ve InstanceHardnessThreshold, ADASYN ve OneSidedSelection tekniğinin genel anlamda daha yüksek başarı artışı (%12) sağladığı belirlenmiştir.

Örnekleme tekniklerinin uygulanıp (fazla örnekleme ve az örnekleme) uygulanmama (örneklemez) durumlarının MÖ algoritmalarının performansına olan etkileri farklı metrikler açısından Tablo 11'de karşılaştırılmıştır. Burada her bir durum için farklı başarı metrikleri açısından model performansları ayrı ayrı değerlendirilerek, elde edilen en yüksek değerler özetlenmiştir. Tablo 11'den de açıkça görüldüğü üzere, farklı örnekleme teknikleri uygulanan MÖ algoritmalarının performansı F1 skoru açısından değerlendirildiğinde en yüksek başarıyı az örnekleme tekniği kullanıldığında XGBoost, LightGBM ve ETC (%78) algoritmaları sergilemiştir. Duyarlılık metriği açısından en yüksek başarı değeri az örnekleme tekniğiyle LightGBM algoritmasıyla (%94) elde edilmiştir. Kesinlik metriği açısından en yüksek başarı değeri XGboost ve LightGBM algoritmalarına (%92) az örnekleme tekniğinin uygulanması durumunda ulaşılmıştır. AUC metriği açısından elde edilen en yüksek değer az örnekleme tekniği uygulanan XGboost algoritmasında (%89) görülmüştür. Son olarak doğruluk metriği açısından ise en yüksek doğruluk değeri %82 ile az örnekleme teknikleri uygulanan XGBoost ve LightGBM elde edilmiştir. Genel olarak, XGBoost ve LightGBM algoritmaları farklı metriklerde benzer performans

sergilemiştir. Ancak XGBoost, F1 skoru ve AUC metriği açısından biraz daha iyi bir performans göstermiştir. Bu nedenle, F1-skor, doğruluk ve AUC metriklerine dayanarak, XGBoost'un LightGBM'den daha yüksek performansa sahip olduğu belirlenmiştir.

Literatürde benzer veri seti kullanarak yapılan çalışmalar Tablo 12'de verilmiştir. Tablodan da görüldüğü üzere KY tanılı hastaların sağkalımlarının tahmininde daha yüksek başarımlar elde edilen çalışmalar mevcuttur. Ancak gerçekleştirilen çalışma dengesiz veri setlerinde örnekleme tekniklerinin model başarımı üzerindeki etkilerinin ele alınması açısından mevcut çalışmalardan ayrılmaktadır.

Dengesiz veri setlerinde örnekleme tekniklerinin uygulanması önem arz etmektedir. Çünkü çoğunluk sınıfı odaklanan modeller, azınlık sınıfı göz ardı edebilmekte, bu da model performansını etkilemektedir. Örnekleme teknikleri, sınıflar arasındaki dengesizliği azaltarak daha doğru ve adil tahminler yapılmasını sağlamaktadır. Elde edilen bulgular dengesiz veri setlerinde örnekleme yönteminin kullanılmasının performans üzerinde etkili olduğu gösterilmiştir.

Tablo 11. Kullanılan algoritmalar için elde edilen en iyi sonuçlar

Algoritma	Örnekleme Yöntemi	En İyi F1Skoru	En İyi Duyarlılık	En İyi Kesinlik	En Doğruluk	En İyi AUC
RO	Örneklemez	0,59	0,68	0,52	0,70	0,83
	Fazla Örnekleme	0,68	0,75	0,68	0,75	0,86
	Az Örnekleme	0,74	0,72	0,88	0,77	0,87
Adaboost	Örneklemez	0,59	0,75	0,48	0,72	0,84
	Fazla Örnekleme	0,73	0,84	0,64	0,80	0,87
	Az Örnekleme	0,75	0,88	0,88	0,80	0,88
XGboost	Örneklemez	0,68	0,79	0,60	0,77	0,86
	Fazla Örnekleme	0,74	0,82	0,68	0,80	0,88
	Az Örnekleme	0,78	0,83	0,92	0,82	0,89
LightGBM	Örneklemez	0,68	0,88	0,56	0,78	0,88
	Fazla Örnekleme	0,75	0,81	0,72	0,80	0,88
	Az Örnekleme	0,78	0,94	0,92	0,82	0,88
DVM	Örneklemez	0,65	0,78	0,56	0,75	0,82
	Fazla Örnekleme	0,76	0,78	0,76	0,80	0,83
	Az Örnekleme	0,76	0,75	0,84	0,78	0,85
GB	Örneklemez	0,54	0,83	0,40	0,72	0,86
	Fazla Örnekleme	0,68	0,93	0,56	0,78	0,88
	Az Örnekleme	0,73	0,93	0,84	0,80	0,88
ETC	Örneklemez	0,65	0,78	0,56	0,75	0,88
	Fazla Örnekleme	0,68	0,93	0,64	0,78	0,88
	Az Örnekleme	0,78	0,83	0,84	0,80	0,87

Tablo 12. Literatürde aynı veri seti kullanılarak yapılan çalışmaların karşılaştırılması

Yazarlar	Yöntem	Doğruluk (%)
Chicco ve Jurman [7]	LR	83.8
Mamun ve ark [12]	LightGBM	85
Awan ve ark. [27]	RO	76
Princy ve ark. [28]	KA	73
Bharti ve ark. [29]	KNN	84.8
Önerilen model	XGboost+ EditedNearestNeighbours	82

4. Sonuç ve Tartışma

KY, yüksek ölüm oranlarına sahip ve son yıllarda artış gösteren ciddi bir kalp hastalığıdır. Bu çalışmada, KY tanılı hastalarının sağkalımlarının doğru bir şekilde tahmin

etmek amacıyla MÖ temelli hibrid bir model önerilmiştir. Model korelasyon temelli özellik seçimiyle tespit edilen anlamlı özelliklerle oluşturulmuş ve yedi farklı MÖ algoritmasının performansı on üç farklı yeniden örnekleme

tekniki kullanılarak değerlendirilmiştir. Tüm örnekleme teknikleri ve sınıflandırma algoritmaları arasında farklı başarımları açısından yapılan genel değerlendirmeler neticesinde en iyi performansı EditedNearestNeighbours az örnekleme tekniğiyle uygulanan XGBOOST algoritmasının sergilediği tespit edilmiştir. Literatürde aynı veri seti üzerinde daha yüksek başarımlar elde eden çalışmalar bulunmaktadır. Ancak bu çalışmada mevcuttakilerden farklı olarak veri seti 80:20 oranında bölünerek yeniden örnekleme tekniklerinin KY hastalarının sağkalımlarının tahmininin üzerindeki etkileri irdelenmiştir. Elde edilen bulgular ışığında dengesiz veri setlerinde örnekleme yönteminin kullanılmasının performans üzerinde etkili olduğu tespit edilmiştir. Ancak çalışmamızda veri setinin sınırlı olması gibi bazı sınırlılıklar bulunmaktadır. Bu nedenle gelecekte yapılması planlanan çalışmalarda farklı sınıflandırıcıları bir araya getiren bir topluluk öğrenme modeli oluşturulması ve daha yüksek başarımların elde edilmesi konuları ele alınacaktır. Bunun için daha geniş bir veri seti kullanılarak, farklı model doğrulama teknikleri, farklı veri ön işleme aşamaları ve özellik seçme yöntemlerinin kullanılması planlanmaktadır.

5. Kaynaklar

- [1] G. Lippi, and F. Sanchis-Gomar, "Global epidemiology and future trends of heart failure", AME Medical Journal, vol. 1, no.15, pp.1-6, 2020.
- [2] A. Feher, B. Bednarski, R. J. Miller, A. Shanbhag, M. Lemley, L. Miras, Miras, Albert J. Sinusas, Edward J. Miller and P. J. Slomka, "Artificial intelligence predicts hospitalization for acute heart failure exacerbation in patients undergoing myocardial perfusion imaging", Journal of Nuclear Medicine, vol. 65, no. 5, pp. 768-774, 2024.
- [3] İ.Ş. Yapıcı, R. U. Arslan, and O. ErKaymaz, "Kalp yetmezliği tanılı hastaların hayatta kalma tahmininde topluluk makine öğrenme yöntemlerinin performans analizi", Karaelmas Fen ve Mühendislik Dergisi, vol. 14, no. 1, pp. 59-69, 2024.
- [4] T. Ahmad, A. Munir, S. H: Bhatti, M. Aftab, and M. A. Raza, "Survival analysis of heart failure patients: A case study", PloS One, vol. 12, no. 7, p.e0181001, 2017.
- [5] İ. Atacak, "Kalp yetmezliği tahmininin kategorik olarak farklı tip makine öğrenmesi yöntemleri ile uygulanmasına yönelik bir değerlendirme çalışması", EMO Bilimsel Dergi, vol. 14, no. 1, pp. 73-85, 2024.
- [6] F.S. Alotaibi, "Implementation of machine learning model to predict heart failure disease", International Journal of Advanced Computer Science and Applications, vol. 10, no. 6, pp.261- 268, 2019.
- [7] D. Chicco, and G. Jurman, "Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone", BMC Medical Informatics and Decision Making, vol. 20, no. 1, pp.1-16, 2020.
- [8] Ç. B. Erdaş and D. Ölçer, "A Machine Learning-Based Approach to Detect Survival of Heart Failure Patients," 2020 Medical Technologies Congress (TIPTEKNO), Antalya, Turkey, 2020, pp. 1-4, doi: 10.1109/TIPTEKNO50054.2020.9299320.
- [9] Y. Chen, X. Qin, L. Zhang, and B. Yi, "A novel method of heart failure prediction based on DPCNN-Xgboost model", Computers, Materials & Continua, vol. 65, no.1, pp. 495-510, 2020.
- [10] A. Ishaq, S. Sadiq, M. Umer, S. Ullah, S. Mirjalili, V. Rupapara, and M. Nappi, "Improving the prediction of heart failure patients' survival using SMOTE and effective data mining techniques", IEEE access, vol. 9, pp. 39707-39716, 2021.
- [11] N. S. Mansur Huang, Z. Ibrahim, and N. Mat Diah, "Machine learning techniques for early heart failure prediction", Malaysian Journal of Computing, vol. 6, no. 2, pp. 872-884,2021.
- [12] M. Mamun, A. Farjana, M. A. Mamun, M. S. Ahammed and M. M. Rahman, "Heart failure survival prediction using machine learning algorithm: am I safe from heart failure?," 2022 IEEE World AI IoT Congress (AIIoT), Seattle, WA, USA, 2022, pp. 194-200, doi: 10.1109/AIIoT54504.2022.9817303.
- [13] M. Muntasir Nishat, F. Faisal, I. Jahan Ratul, A. Al-Monsur, A. M. Ar-Rafi, S. M. Nasrullah, M. T. Reza and M. R. H. Khan, "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, vol. 2022, pp. 1-17, 2022.
- [14] F. A. Özbay, and E. Özbay, "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, 2022.
- [15] R. K. Sachdeva, K. D. Singh, S. Sharma, P. Bathla and V. Solanki, "An Organized Method for Heart Failure Classification," 2023 International Conference on Emerging Smart Computing and Informatics (ESCI), Pune, India, 2023, pp. 1-6, doi: 10.1109/ESCI56872.2023.10099809.
- [16] M. Mudassar, M. Afzal and T. Muhammad, "A Machine Learning Based Predictive Model to Diagnose Heart Failure Patients using Imbalanced Classification Problem," 2023 4th International Conference on Advancements in Computational Sciences (ICACS), Lahore, Pakistan, 2023, pp. 1-8, doi: 10.1109/ICACS55311.2023.10089759.
- [17] S. B. Keser, and K. Keskin, "Kalp yetmezliği hastalarının sağ kalım tahmini: Sınıflandırmaya dayalı makine öğrenmesi algoritmalarının bir uygulaması", Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, vol. 23, no. 2, pp. 362-369, 2023.
- [18] R. Ghorbani and R. Ghousi, "Comparing Different Resampling Methods in Predicting Students' Performance Using Machine Learning Techniques," in IEEE Access, vol. 8, pp. 67899-67911, 2020, doi: 10.1109/ACCESS.2020.2986809.

- [19] M. A. Aydın, "Müşteri Kaybı Tahmininde Sınıf Dengesizliği Problemi", *Politeknik Dergisi*, vol. 25, no. 1, pp. 351 - 360, 2020.
- [20] R. Uzun, Y. Isler and M. Toksan, "Use of Support Vector Machines to Predict the Success of Wart Treatment Methods," 2018 Innovations in Intelligent Systems and Applications Conference (ASYU), Adana, Turkey, 2018, pp. 1-4, doi: 10.1109/ASYU.2018.8554010.
- [21] S. Gündoğdu, "Efficient prediction of early-stage diabetes using XGBoost classifier with random forest feature selection technique", *Multimedia Tools and Applications*, vol. 82, no. 22, pp. 34163-34181, 2023.
- [22] N. Q. K. Le, D. T. Do, and Q. A. Le, "A sequence-based prediction of Kruppel-like factors proteins using XGBoost and optimized features", *Gene*, vol. 787, pp. 145643, 2021.
- [23] K. Karthick, S. K., Aruna, R. Samikannu, R. Kuppusamy, Y. Teekaraman, and A. R. Thelkar, "Implementation of a heart disease risk prediction model using machine learning", *Computational and Mathematical Methods in Medicine*, vol. 2022, pp. 6517716, 2022.
- [24] W. Wang, and D. Sun, "The improved AdaBoost algorithms for imbalanced data classification", *Information Sciences*, vol. 563, pp. 358-374, 2021.
- [25] L. Abhishek, "Optical Character Recognition using Ensemble of SVM, MLP and Extra Trees Classifier," 2020 International Conference for Emerging Technology (INCET), Belgaum, India, 2020, pp. 1-4, doi: 10.1109/INCET49848.2020.9154050.
- [26] R. Uzun, Y. Isler, and M. Toksan, "Prediction of the Success of Wart Treatment Methods", *Karaelmas Fen Ve Mühendislik Dergisi*, vol. 10, no. 1, pp. 44-52, 2020.
- [27] S. E. Awan, M. Bennamoun, F. Sohel, F. M. Sanfilippo, and G. Dwivedi, "Machine learning-based prediction of heart failure readmission or death: implications of choosing the right model and the right metrics," *ESC heart failure*, vol. 6, no. 2, pp. 428-435, 2019.
- [28] R. J. P. Princy, S. Parthasarathy, P. S. H. Jose, A. R. Lakshminarayanan, and S. Jeganathan, "Prediction of cardiac disease using supervised machine learning algorithms," In 2020 4th International Conference on Intelligent Computing and Control Systems, pp. 570-575.
- [29] R. Bharti, A. Khamparia, M. Shabaz, G. Dhiman, S. Pande, and P. Singh, "Prediction of heart disease using a combination of machine learning and deep learning," *Computational intelligence and neuroscience*, vol. 2021, 8387680, 2021.

Özgeçmişler



Dr. Rukiye Uzun Arslan, 2004 yılında Sivas Cumhuriyet Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan Rukiye UZUN ARSLAN, yüksek lisans eğitimini 2010 yılında, doktorasını ise 2014 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünde doçent olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.



Dr. İrem Şenyer Yapıcı, 2012 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan İrem ŞENYER YAPICI, yüksek lisans eğitimini 2016 yılında, doktorasını ise 2021 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Zonguldak Bülent Ecevit Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde doktor öğretim üyesi olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.