

Makine Öğrenmesi Yöntemleri ile Finansal Başarısızlık Tahmini: İmalat Firmalarından Kanıtlar

Fahrettin Söker¹

Özet

Bu çalışma, ağaç tabanlı makine öğrenme yöntemlerini kullanarak Borsa İstanbul'da işlem gören imalat sektörü firmalarının finansal başarısızlığını tahmin etmeyi ve en başarılı yöntemi belirlemeyi amaçlamaktadır. Tahmin sürecinde Rastgele Orman (Random Forest - RF) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting - XGB) modelleri kullanılmış, 204 firmanın 2023-2024 dönemi verileriyle finansal başarısızlığı tahmin edilmiştir. Tahmin sonuçlarında RF modelinin daha başarılı performans sergilediği, ayrıca modellerin tahminine en çok katkısı sunan değişkenin Esas Faaliyet Kârı / Kısa Vadeli Borçlar oranı olduğu tespit edilmiştir. Sonuçlar finansal başarısızlık tahminlerinde iki farklı ağaç tabanlı makine öğrenmesi yönteminin performansını imalat sektöründen verilerle ortaya koymakta ve tahminlerde kısa vadeli borçları ödeyebilme kapasitesi olarak esas faaliyet karlılığını öne çıkarmaktadır.

1. Giriş

Finansal başarısızlık, bir firmanın cari yükümlülüklerini vadesinde ödeyememesi olarak tanımlanır (Beaver, 1966, s. 71; Zeytinoğlu & Akarım, 2013, s. 107). Başarısızlıkla sonuçlanan süreçte ortaya çıkan finansal yapıdaki bozulmalar, firmaların faaliyetlerini sürdürebilme yeteneği konusunda endişelere yol açmaktadır (Ayvaz & Erkan, 2023, s. 376). Başarısızlıkta, kreditorlerin alacaklarını tahsil edememeleri ve hissedarların sahip oldukları payların değerlerini kaybetmeleri gibi durumlar ortaya çıkabilir (Yaman & Korkmaz, 2021, s. 593). Dahası, firmaların iflas etmesine veya tasfiye sürecine girmesine neden olabilir (Zeytinoğlu & Akarım, 2013, s. 107).

1 Öğr. Gör. Dr., Kahramanmaraş İstiklal Üniversitesi, fahrettin.soker@istiklal.edu.tr, ORCID: 0000-0002-3763-5419

Bu sebeple firmaların finansal başarısızlığının tahmin edilmesi yöneticilerin, yatırımcıların ve hissedarların karar alma süreçleri için kritik öneme sahiptir (Xu & Wang, 2009, s. 366).

Finansal başarısızlığın tahminiyle yöneticiler başarısızlık ihtimaline karşı borçlanma, maliyet yönetimi gibi konularda önceden iyileştirici önlemler alabilir. Yatırımcılar ise iflas riski ve finansal sıkıntının oluşturduğu kritik duruma göre kararlarını şekillendirerek, yüksek riskli firmalara yapılacak yatırımlarda daha sağlıklı kararlar alabilir (Yaman & Korkmaz, 2021, s. 593). Dolayısıyla finansal başarı/başarısızlık tahminleri firma ve paydaşları için risklerin azaltılmasına ve kaynakların daha etkin kullanılmasına imkân sağlar.

Bir firmanın ciddi kayıplar yaşaması ve/veya varlıklarına oranla orantısız yükümlülüklerle sahip olması durumunda ortaya çıkan finansal başarısızlığın yaygın olarak belirlenen nedenleri ve belirtileri arasında kötü yönetim, piyasada başarılı bir şekilde faaliyet göstermede yaşanan zorluklar gibi sorunlar yer almaktadır (Gestel vd., 2006, s. 380). Dolayısıyla bir firmanın başarısızlığı aniden ortaya çıkmamakta, dengesiz bir finansal yapı, likidite ve ödeme gücünde bozulma gibi faktörler firmayı başarısızlık sarmalına sürüklemektedir (Zizi vd., 2020, s. 1). Böylece finansal başarısızlık tahmin modellerinde, genellikle çeşitli finansal oranlar değişken olarak seçilmekte ve bu durum finansal oranların finansal başarısızlığın olası nedenini temsil ettiğini ifade etmektedir (Xu & Wang, 2009, s. 366). Bu bağlamda Altman (1968), finansal oranları kullanarak Z skoru geliştirmiş ve bu skor çeşitli finansal oranlar aracılığıyla firmaların iflas olasılığını belirlemeye çalışarak finansal başarısızlığı anlama ve tahmin etmeye yönelik ilk ve öncü sistematik yaklaşımlardan biri olarak literatürde yerini almıştır (Gülal vd., 2023, s. 661). Son yıllarda ise makine öğrenmesi tekniklerinin finans alanındaki tahminlerde önemli gelişim göstermesi, finansal başarı veya başarısızlığın tahmininde bu yöntemlerin kullanılmasının önünü açmış ve başarılı sonuçların elde edildiği belirlenmiştir (Soydaş, 2021; Aker & Karavardar, 2023; Gülal vd., 2023). Makine öğrenmesi yöntemleri doğrusal, ağaç tabanlı, sinir ağları gibi birçok yöntemi içinde barındırmakta, sınıflandırma ve regresyon problemleri için verilerden öğrenip öğrendiğini test ederek çözümler sunmaktadır.

Bu çalışmada Borsa İstanbul'da işlem gören imalat sektörü firmalarında ağaç tabanlı makine öğrenmesi yöntemleri ile finansal başarısızlık tahmini yapılmıştır. Tahmin sürecinde makine öğrenmesi modelleri kapsamında Rastgele Orman (Random Forest - RF) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting - XGB) modelleri kullanılmış, 204 firmanın 2023 yılına ait finansal verileriyle 2024 yılındaki finansal başarısızlığın tahmin edilmesinde

en başarılı olan modelin tespit edilmesi amaçlanmıştır. Böylece çalışmada finansal başarısızlık tahminlerinde iki farklı ağaç tabanlı makine öğrenmesi yönteminin başarısı imalat sektöründen verilerle ortaya konmaktadır.

Çalışmanın içeriği ise şu şekildedir. İlk bölümde finansal başarısızlık konusunda kavramsal çerçevenin de olduğu giriş bölümü yer almakta, ikinci bölümde literatür taramasına yer verilmekte, üçüncü bölümde çalışmanın metodolojisi, dördüncü bölümde bulgular, beşinci bölümde ise sonuç yer almaktadır.

2. Literatür Taraması

Literatürde firmaların finansal başarısızlığının tahmininde makine öğrenmesi yöntemleri birçok araştırmaya konu olmakta ve son yıllarda şu araştırmalara rastlanabilmektedir.

Hesarı (2018) BIST’te işlem gören firmaların 2009-2014 dönemi verilerini kullanarak karar ağaçları (C&R, QUEST ve CHAID karar ağacı), Yapay Sinir Ağları (YSA), diskriminant analizi ve lojistik regresyon analizi yöntemleriyle firmaların 1 yıl öncesinden finansal başarı/başarısızlığını tahmin etmiştir. Tahmin sonuçlarında en yüksek performansa C&R ağacı modelinde ulaşılmıştır. Yürük ve Ekşi (2019), YSA ve Destek Vektör Makineleri (DVM) modelleriyle 2008-2016 yılları arasında BIST’te işlem gören imalat firmalarının finansal başarısızlığını 1, 2 ve 3 yıl öncesine kadar tahmin etmiştir. Tahmin sonuçlarında YSA’nın bütün tahminlerde DVM’den daha iyi performans sergilediği belirlenmiştir.

Horak vd. (2020), Çek Cumhuriyeti’nde faaliyet gösteren sanayi firmalarında 2013-2017 dönemi verileriyle finansal başarısızlığı YSA ve DVM modellerini kullanarak tahmin etmiştir. Tahmin sonuçlarında çok katmanlı algılayıcı yaklaşımıyla oluşturulan sinir ağları modelinin daha iyi sonuçlar verdiği belirlenmiştir. Aksoy ve Boztosun (2021), BIST’te işlem gören 86 imalat firmasının finansal başarısızlığını 2010-2012 dönemindeki verileriyle YSA, Sınıflandırma ve Regresyon Ağaçları (CART), DVM ve K-En Yakın Komşular (KNN) algoritması yöntemlerini kullanarak 1 ve 2 yıl öncesinden tahmin etmiştir. Çalışma sonucunda bu modellerin 1 ve 2 yıl öncesinden finansal başarısızlığı tahmin etmede yüksek sınıflandırma doğruluğuna sahip olduğu, 1 yıl öncesinden en iyi sınıflandırma doğruluğunu CART modelinin, 2 yıl öncesinden ise DVM modelinin sağladığı belirlenmiştir.

Soydaş (2021) BIST’te işlem gören 178 imalat firmasının 2015-2019 yılları arasındaki finansal verileriyle Altın Z skoru ve makine öğrenmesi yöntemlerini kullanarak finansal başarısızlığı 1 yıldan 5 yıla kadar öncesinde tahmin etmiştir. Tahmin sonuçlarında Rastgele Orman modelinin oldukça

iyi sonuçlar verdiği belirlenmiştir. Özparlak ve Özdemir Dilidüzgün (2022) ABD’de 2018-2020 yılları arasında faaliyette bulunan sağlık sektörü firmalarının finansal başarısızlığını YSA ile tahmin etmiştir. Sonuçlar YSA’nın yüksek sınıflandırma başarısına sahip olduğunu göstermiştir.

Aker ve Karavardar (2023), Türkiye’de faaliyet gösteren 328 KOBİ’nin 2015-2018 yılları arasındaki finansal verilerinden yararlanarak finansal başarısızlığı 1, 2 ve 3 yıl öncesinden tahmin etmek için Altman Z skorunu, Springate S skorunu ve YSA modelini kullanarak en başarılı modeli tespit etmeyi amaçlamıştır. Çalışma sonucunda YSA modelinin en yüksek doğru sınıflandırma oranına ulaşarak en başarılı model olduğu belirlenmiştir. Máté vd. (2023), Pakistan’daki firmaların finansal başarısızlığını 2016-2021 döneminde AdaBoost, Karar Ağaçları, Gradyan Artırma (Gradient Boosting), Lojistik Regresyon, Naive Bayes, Rastgele Orman ve DVM ile tahmin etmiştir. Tahmin sonuçlarında Naive Bayes haricinde diğer modellerin daha başarılı sonuçlar verdiği belirlenmiştir.

Ceyhan (2023), yaptığı çalışmada BIST’te işlem gören 28 firmanın 2022 yılı verileriyle Naive Bayes, J48, Rastgele Orman, Lineer Regresyon, Rastgele Karar Ağacı (Random Tree) modelleri kullanarak finansal başarısızlık tahmini yapmıştır. Rastgele Orman modelinin en iyi sınıflandırma doğruluğuna ulaştığı belirlenmiştir. Erdem ve Bakır (2023), Türkiye’de 2010-2018 yılları arasında Makine ve Ekipman imalatı sektöründe faaliyet gösteren firmaların finansal başarısızlığını, yeniden örnekleme yöntemiyle elde edilen 3 farklı veri setini kullanarak XGB modeli ile tahmin etmiştir. Sonuçlarda SMOTE algoritması kullanılarak oluşturulan veri seti ile 2018 yılı finansal başarısızlığı tahmin etmek için yapılan XGB modellemesinde en yüksek sınıflandırma doğruluğuna ulaşıldığı belirlenmiştir. Gülal vd. (2023), BIST Sanayi endeksi firmalarının finansal başarısızlığını K-Means algoritması, Altman Z skoru ve S skoru kullanarak 2011-2021 yılları arasında tahmin etmiştir. Tahmin sonuçları K-Means algoritmasının diğer yöntemlere göre daha doğru kümeleme sonuçları verdiği belirlenmiştir.

Yapa ve Coşkun (2024), Tarım, Ormanlık ve Balıkçılık sektöründe 2009-2019 yılları arasında faaliyet gösteren firmaların verileriyle Rastgele Orman, Lojistik Regresyon, YSA ve KNN yöntemlerini kullanarak yaptığı finansal başarısızlık tahmininde, Rastgele Orman modelinin yüksek seviyede doğruluk, kesinlik ve hassasiyet oranına ulaştığını belirlemiştir. Iparraguirre-Villanueva ve Cabanillas-Carbonell (2024) çok sayıda firmanın finansal başarısızlıklarını 16 farklı makine öğrenmesi modelleri ile tahmin etmiştir. Tahmin sonuçlarında Stacking Classifier (SCC), Rastgele Tabanlı

Sınıflandırıcı (RCV), Karar Ağacı Sınıflandırıcısı (DTC) modellerinin daha iyi performans gösterdiği belirlenmiştir.

Literatürdeki çalışmalarda Yapay Sinir Ağları, Destek Vektör Makineleri gibi makine öğrenmesi modellerinin yanı sıra ağaç tabanlı modellerinde sıklıkla finansal başarısızlığın tahmininde kullanıldığı görülmektedir. Bu çalışmada ağaç tabanlı modellerden Rastgele Orman ve XGB modelleri kullanılmaktadır. Literatür bu modeller açısından incelendiğinde tahminlerde başarılı performans elde edildiği belirlenmektedir (Soydaş, 2021; Erdem & Bakır, 2023; Ceyhan, 2023; Máté vd., 2023; Yapa & Coşkun, 2024).

3. Metodoloji

3.1. Veri Seti ve Değişkenler

İmalat sektörü firmalarında finansal başarısızlığın tahmin edildiği bu çalışmada Borsa İstanbul'da işlem gören 204 imalat firmasının 2023 ve 2024 yılındaki yıllık finansal tablolarına ait verileri kullanılmıştır. Veriler Finnet üzerinden elde edilmiş, verilerle oluşturulan değişkenlere ilişkin açıklamalara Tablo 1'de yer verilmiştir. Çalışmada analizde kullanılan makine öğrenmesi modellerinde firmaların 2024 yılındaki finansal başarısızlığı, 2023 yılına ait veriler ile tahmin edilmiştir. Bu süreçte firmaların 2024 yılındaki finansal başarısızlığının tespiti için Altan ve Demirci (2022, s. 407)'nin literatür incelemeleri ile belirlediği finansal başarısızlık ölçütlerinden ve Aksoy ve Boztosun (2021, s. 62)'un çalışmasında kullandığı ölçütlerden yararlanılarak son 2 yıl net karlılığa, nakit ve nakit benzerlerindeki net artışa, son yıl %10'dan yüksek aktif büyüklüğü ile %10'dan yüksek öz sermaye büyüklüğüne ve pozitif net işletme sermayesine sahip olma ölçütleri firmaların finansal başarı ölçütü olarak kullanılmıştır.

Tablo 1. Analizde Kullanılan Değişkenler

Değişkenler	Açıklamalar
FB	Son 2 yıl net karlılık ile nakit ve nakit benzerlerindeki net artışa, son yıl %10'dan yüksek aktif büyüklüğüne, %10'dan yüksek öz sermaye büyüklüğüne ve pozitif net işletme sermayesine sahip olma ölçütlerini sağlayan firmaların başarılı, bu ölçütleri sağlamayan firmaların başarısız olarak belirlenmesi sonucunda başarısız firmalar için 1, başarılı firmalar için 0 değerinin atandığı Finansal Başarısızlık (FB) kukla değişkenini ifade etmektedir.
CO	Dönen varlıkların kısa vadeli borçlara oranını ifade eden Cari Oranı (CO),
DV	Dönen varlıkların toplam varlıklara oranını ifade eden Dönen Varlık Oranını (DV),

BKM	Brüt kârın net satışlara oranını ifade eden Brüt Kâr Marjını (BKM),
EFKM	Esas faaliyet kârının net satışlara oranını ifade eden Esas Faaliyet Kâr Marjını (EFKM),
NSB	Net satışlardaki yıllık yüzdelik büyümeyi (NSB)
BS	Toplam borçların öz sermayeye oranını (BS),
EFKB	Esas faaliyet kârının kısa vadeli borçlara oranını (EFKB),
KVBV	Kısa vadeli borçların toplam varlıklara oranını (KVBV)
VD	Net satışların toplam varlıklara oranı ile hesaplanan Toplam Varlık Devir Hızını (VD),
PD	Pay senedi Piyasa Değeri ile Defter Değeri oranını (PD) belirtmektedir.

3.2. Yöntem

Bu çalışmada finansal başarısızlığın tahmin edilmesi için ağaç tabanlı makine öğrenmesi modelleri kapsamında Rastgele Orman (Random Forest) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting - XGB) modelleri kullanılmıştır. Bu modeller bilimsel Python geliştirme ortamı olan Spyder IDE kullanılarak analiz edilmiştir.

3.2.1. Rastgele Orman (Random Forest)

İstatistikte ve makine öğrenmesi alanlarında tercih edilen karar ağacı tabanlı yöntemlerden biri olan Rastgele Orman (Random Forest - RF) Breiman (2001) tarafından geliştirilen bir yöntemdir. RF, torbalama ve rastgele değişken seçimi yoluyla eğitilen farklı regresyon ağaçlarının kombinasyonundan oluşan bir tahmin modelidir (Wang vd., 2018, s. 13). RF'de temel prensip birkaç temel öğreniciyi bağımsız olarak oluşturmak ve ardından sonuçların ortalamasını alarak bir birleştirici elde etmektir (Wang vd., 2019, s. 3). Bu tahmin yaklaşımı büyük hata riskini azaltmakta ve RF tahminlerini bileşen ağaçlarının herhangi birinden daha doğru hale getirmektedir (Wang vd., 2018, s. 13). Genel olarak bu yöntem, tahminler yapmada oldukça doğru, karmaşık bir veri setine uygulanabilen, yüksek boyutlu verileri işlemede verimli, eksik değerleri yüksek doğrulukla tahmin edebilen ve giriş parametrelerinin hedef değişken üzerindeki önem düzeylerini belirleyebilen esnek ve pratik bir yöntemdir (Alawi vd., 2024, s. 7). RF yönteminde ilk eğitim verisinden rastgele örnekleme yapılarak birden fazla yeni eğitim verisi oluşturmakta, daha sonra değişken kümesi rastgeleleştirmesi eklenerek her yeni eğitim veri kümesi için tüm değişkenlerden oluşan kümeden rastgele örnekleme ile rastgele değişken kümesi elde edilmekte, sonrasında her ağaç bölme noktalarında rastgele değişken kümesindeki değişkenler altında en iyi bölünmeyi arayarak

büyümekte ve tüm ağaçlar geliştirildikten sonra tahminleme için ortalama alınarak ağaçlar birleştirilmektedir (Wang vd., 2018, s. 13).

3.2.2. Aşırı Gradyan Artırma (Extreme Gradient Boosting)

Aşırı Gradyan Artırma (Extreme Gradient Boosting - XGB) Chen ve Guestrin (2016) tarafından önerilen ve Gradient Boosting (GB) modelini baz alarak oluşturulan bir makine öğrenmesi yöntemidir. Friedman (2001)'in önerdiği ağaç tabanlı bir model olan GB modeli, sınıflandırma ve regresyon problemleri için zayıf tahmin modelleri topluluğu biçimindeki bir modeli kullanmaktadır (Larestani vd., 2022, s. 6). Yöntemin temel mantığı, bir dizi zayıf temel sınıflandırıcıyı güçlü bir sınıflandırıcıda birleştirmektir (Rao vd., 2019, s. 635). Yöntemde temel öğrenici sırayla oluşturularak birleştiricinin sapması azaltılmaya çalışılır (Wang vd., 2019, s. 3). XGB'nin algoritması da zayıf öğrenenlerden oluşan bir kümenin tüm tahminlerini eklemeli eğitim stratejileri aracılığıyla güçlü bir öğrenen geliştirmek için birleştiren "Boost" fikrinden türetilerek aşırı uyum sorununu önlemeyi ve aynı zamanda algoritma çalışırken harcanan işlem gücü ve zaman gibi tahmin maliyetlerini en aza indirmeyi amaçlamaktadır (Fan vd., 2018, s. 230). Yöntemde model karmaşıklığının düzenlenmesi için kayıp fonksiyonuna düzenli bir terim eklenir ve hata-varyans dengesinden bakıldığında, GB modeline göre bir avantaj olarak düzenli terimler modelinin varyansı azaltılır böylece aşırı uyum sorunu önlenir (Wang vd., 2019, s. 4).

3.3. Performans Ölçütleri

Bu çalışmanın temel amacı doğrultusunda finansal başarısızlığı tahmin etmede RF ve XGB modelleri karşılaştırılmaktadır. Dolayısıyla tahminlemede en iyi performansı sağlayan modeli belirlemek hedefiyle performans ölçütü olarak Accuracy (Doğruluk), F1 skoru ve ROC-AUC (Receiver Operating Characteristic - Area Under the Curve) ölçütleri kullanılmıştır.

Doğruluk ölçütü sınıflandırma tahminlerinin değerlendirilmesinde tahmini değerler ile gerçek değerlerin ne kadar eşleştiği göstermekte (Olu-Ajayi vd., 2023, s. 9) ve yapılan doğru tahminlerin toplamının, yapılan toplam tahmin sayısına oranı ile hesaplanmaktadır (Egwim vd., 2021, s. 10). Doğruluk ölçütünün hesaplandığı denklem aşağıda gösterilmektedir (Olu-Ajayi vd., 2023, s. 9).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Denklem 1'de TP ve TN (Doğru Pozitif ve Doğru Negatif) tahmin edilen ve gerçek değerler arasındaki doğru sınıflandırılmaları temsil etmekte, FP ve

FN (Yanlış Pozitif ve Yanlış Negatif) ise tahmin edilen ve gerçek değerler arasındaki yanlış sınıflandırmaları ifade etmektedir.

F1 skoru, pozitif tahminlerinin doğruluğunu ölçen kesinlik (precision) ile sınıflandırıcı tarafından doğru şekilde tespit edilen pozitif örneklerin oranını gösteren duyarlılığın (recall) harmonik ortalamasını temsil eder ve aşağıda yer alan denklem 2 ile hesaplanmaktadır (Michalkova & Ponisciakova, 2025, ss. 7-8; Egwim vd., 2021, s. 10). Hesaplama, bire yakın puan en iyi, sıfıra en yakın puan ise en kötü puan olarak kabul edilmektedir (Olu-Ajayi vd., 2023, s. 9).

$$F1 \text{ Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2)$$

ROC-AUC, bir sınıflandırıcının genel performansının en iyi göstergesi olarak kabul edilen ROC eğrisinin altındaki alanı (AUC) belirtmekte, mükemmel doğruluğu gösteren maksimum AUC değeri 1, minimum AUC değeri ise 0,5 olarak gerçekleşmektedir (Egwim vd., 2021, ss. 10-11).

3.4. Model Geliştirme

Çalışmada analiz sürecinde kullanılan RF ve XGB modellerinde firmaların 2024 yılındaki finansal başarısızlığı 2023 yılına ait veriler ile tahmin edilmiştir. Modellerde FB değişkeni hedef değişken olarak, CO, DV, BKM, EFKM, NSB, BS, EFKB, KVBV, VD ve PD değişkenleri ise girdi değişkenleri olarak kullanılmıştır. Modellerde, verilerin %80'i eğitim verisi, %20'si ise test verisi olarak belirlenmiştir. Modellerdeki parametre aralıkları da tablo 2'de yer almaktadır. Tablo 2'deki parametre aralıklarının optimizasyonu Accuracy (Doğruluk) dikkate alınarak 10 katlı çapraz doğrulamanın olduğu "GridSearchCV" yöntemi ile gerçekleştirilmiştir.

Tablo 2. Model Parametreleri

	Parametre Aralıkları	En İyi Parametreler
RF	'n_estimators': [200, 300, 400],	'n_estimators': 200,
	'max_depth': [1, 2, 3],	'max_depth': 3,
	'min_samples_split': [4, 6, 8],	'min_samples_split': 4,
	'min_samples_leaf': [2, 3],	'min_samples_leaf': 3,
	'max_features': [0.4, 0.5],	'max_features': 0.5,
	'max_samples': [0.5, 0.6],	'max_samples': 0.5
XGB	'n_estimators': [200, 300, 400],	'n_estimators': 400,
	'max_depth': [1, 2, 3],	'max_depth': 1,
	'min_child_weight': [4, 6, 8],	'min_child_weight': 8,
	'gamma': [2, 3],	'gamma': 3,
	'colsample_bytree': [0.4, 0.5],	'colsample_bytree': 0.5,
	'subsample': [0.5, 0.6]	'subsample': 0.5

4. BULGULAR

4.1. Tanımlayıcı İstatistikler

Çalışmada analizlerde kullanılan değişkenlere ait tanımlayıcı istatistiklere Tablo 3'te yer verilmiştir. Tablo 3 incelendiğinde analize alınan değişkenlerin 204 gözlemden oluştuğu, değişkenlerden FB'nin ortalama 0,44 olduğu görülmektedir. Dolayısıyla analize alınan firmaların %44'sinin başarısız, %56'sının başarılı olduğu belirlenmektedir. Finansal başarısızlığı tahmin etmek için kullanılan değişkenler özet olarak ortalama itibariyle değerlendirildiğinde CO'nun (Cari Oran) 2'ye yakın, DV'nin (Dönen Varlık Oranı) %49, BKM'nin (Brüt Kar Marjı) 0,22, EFKM'nin (Esas Faaliyet Kar Marjı) 0,09, NSB'nin (Net Satışlardaki Büyüme) %39, BS'nin (Toplam Borcun Öz Sermayeye Oranı) 0,96, EFKB'nin (Esas Faaliyet Kârının Kısa Vadeli Borçlara Oranı) 0,33, KVBV'nin (Kısa Vadeli Borçların Toplam Varlıklara Oranı) %32, VD'nin (Toplam Varlık Devir Hızı) 0,89 ve PD'nin (Piyasa Değeri Defter Değeri Oranı) 2,07 olduğu belirlenmektedir.

Tablo 3. Tanımlayıcı İstatistikler

	FB	CO	DV	BKM	EFKM	NSB	BS	EFKB	KVBV	VD	PD
Ort.	0,44	1,99	0,49	0,22	0,09	0,39	0,96	0,33	0,32	0,89	2,07
Medyan	0,00	1,51	0,50	0,20	0,09	0,41	0,68	0,22	0,30	0,82	1,38
Maks.	1,00	15,7	0,97	0,80	0,36	1,92	5,49	2,76	0,79	2,90	18,1
Min.	0,00	0,23	0,07	-0,24	-0,52	-0,74	0,08	-1,28	0,03	0,07	0,21
Gözlem	204	204	204	204	204	204	204	204	204	204	204


4.2. Model Tahmin Sonuçları

Tablo 4'te analize alınan firmaların finansal başarısızlığının tahmin edildiği RF ve XGB modellerine ait doğruluk, F1 skoru ve ROC-AUC ölçütü sonuçları yer almaktadır. Sonuçlar değerlendirildiğinde eğitim ve test değerlerinin yakın olduğu görülmekte ve bu durum modellerin genelleme kabiliyetine sahip olduğunu göstermektedir. Test değerleri itibariyle model performansları karşılaştırıldığında doğruluk ölçütü sonuçlarından RF modelinde %78,05 oranında sınıflandırma başarıları performansı elde edilmekte, XGB modelinde ise %70,73 oranında sınıflandırma başarıları tespit edilmektedir. F1 skoru itibariyle RF modelinin 0,7568 ile XGB modelinden (0,70) daha iyi olduğu, ROC-AUC ölçütü itibariyle ise yine RF modelinin 0,8478 ile XGB modelinden (0,7754) daha iyi olduğu belirlenmektedir.

Tablo 4. Model Performans Sonuçları

	Performans Ölçütü	Rastgele Orman (RF)	Aşırı Gradyan Artırma (XGB)
Eğitim	Doğruluk	0.8098	0.7423
Test		0.7805	0.7073
Eğitim	F1 Skoru	0.7737	0.7000
Test		0.7568	0.7000
Eğitim	ROC-AUC	0.8951	0.8094
Test		0.8478	0.7754

Şekil 1’de ise model tahminlerinde kullanılan değişkenlerin önem düzeyleri yer almaktadır. Bu düzeyler incelendiğinde finansal başarısızlık tahmininde her iki modelde de en çok katkıyı sağlayan değişken olarak EFKB (Esas Faaliyet Kârının Kısa Vadeli Borçlara Oranı) değişkeninin ilk sırada olduğu görülmektedir.



Şekil 1. Değişken Önem Düzeyleri

5. Sonuç

Finansal başarısızlığın tahmininde makine öğrenmesi yöntemlerinden RF ve XGB modellerinin performansının karşılaştırıldığı bu çalışmada elde edilen model tahmin sonuçlarında RF modelinin daha başarılı sınıflandırma doğruluğuna sahip olduğu ve bu başarının F1 skoru ve ROC-AUC ölçütleriyle desteklendiği belirlenmiştir. Ayrıca finansal başarısızlık tahmininde en çok katkıyı sağlayan değişkenin Esas Faaliyet Kârının Kısa Vadeli Borçlara oranı olduğu tespit edilmiştir. Bu durum finansal başarısızlık tahmininde, kısa vadeli borçları ödeyebilme kapasitesi olarak firmaların esas faaliyetlerinden elde edilen kârlılığın öne çıktığını göstermektedir.

Sonuçlar, finansal başarısızlığın tahmininde ağaç tabanlı makine öğrenmesi modeli kullanımı açısından RF modelinin etkili olduğunu, aynı zamanda bu tahminlemede Esas Faaliyet Kârı / Kısa Vadeli Borçlar oranının öne çıkan değişken olduğunu imalat sektöründen güncel verilerle ortaya koyarak literatüre katkı sağlamaktadır. Son olarak bu çalışmada iki farklı ağaç tabanlı makine öğrenmesi yöntemi kullanılmış ve yalnızca imalat firmalarında finansal başarısızlık tahmini yapılmıştır. Çalışmanın sınırlılığını oluşturan bu durumdan hareketle gelecek çalışmalara, farklı makine öğrenmesi modelleri ile farklı sektörlerinde dahil edildiği tahminlerin yapılması öneri olarak sunulabilmektedir.

Kaynaklar

- Aker, Y., & Karavardar, A. (2023). Using machine learning methods in financial distress prediction: Sample of small and medium sized enterprises operating in Turkey. *Ege Academic Review*, 23(2), 145-162.
<https://doi.org/10.21121/eab.1027084>
- Aksoy, B., & Boztosun, D. (2021). Comparison of classification performance of machine learning methods in prediction financial failure: Evidence from Borsa İstanbul. *Hitit Sosyal Bilimler Dergisi*, 14(1), 56-86.
<https://doi.org/10.17218/hititsbd.880658>
- Alawi, O. A., Kamar, H. M., & Yaseen, Z. M. (2024). Optimizing building energy performance predictions: A comparative study of artificial intelligence models. *Journal of Building Engineering*, 88, 1-18.
<https://doi.org/10.1016/j.jobbe.2024.109247>
- Altan, G., & Demirci, S. (2022). Makine öğrenmesi ile nakit akış tablosu üzerinden kredi skorlaması: XGBoost yaklaşımı. *İktisat Politikası Araştırmaları Dergisi - Journal of Economic Policy Researches*, 9(2), 397-424.
<https://doi.org/10.26650/JEPR1114842>
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.
<https://doi.org/10.2307/2978933>
- Ayvaz, R., & Erkan M. K. (2023). A review on financial failure models- The case of manufacturing industry. *Business & Management Studies: An International Journal*, 11(1), 375-399. <https://doi.org/10.15295/bmij.v11i1.2187>
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, 71-111. <https://doi.org/10.2307/2490171>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5-32.
- Ceyhan, İ. F. (2023). İşletmelerde finansal başarısızlık öngörüsünde makine öğrenmesinin kullanımı: BİST uygulaması. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 8(3), 564-580. <https://doi.org/10.29106/fesa.1359358>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794), New York, NY: Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
- Egwim, C. N., Alaka, H., Toriola-Coker, L. O., Balogun, H., & Sunmola, F. (2021). Applied artificial intelligence for predicting construction projects delay. *Machine Learning with Applications*, 6, 100166.
<https://doi.org/10.1016/j.mlwa.2021.100166>
- Erdem, K. Ş., & Bakır, M. A. (2023). Makine ve ekipman imalatı sektöründe izolasyon ormanı ve yeniden örnekleme yöntemleri kullanılarak finansal başarısızlığın tespit edilmesi. *Verimlilik Dergisi*, 57(4), 719-734.
<https://doi.org/10.51551/verimlilik.1301865>

- Fan, J., Yue, W., Wu, L., Zhang, W., Cai, H., Wang, X., Lu, X., & Xiang, Y. (2018). Evaluation of SVM, ELM and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of China. *Agricultural and Forest Meteorology*, 263, 225-241. <https://doi.org/10.1016/j.agrformet.2018.08.019>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232.
- Gestel, T. V., Baesens, B., Suykens, J. A. K., Poel, D. V. D., Baestaens, D.-E., & Willekens, M. (2006). Bayesian kernel based classification for financial distress detection. *European Journal of Operational Research*, 172, 979-1003.
- Gülal, Ö. S., Seçme, G., & Köse, E. (2023). Predicting financial distress in the BIST industrials index: Evaluating traditional models and clustering techniques. *Ekonomi Politika ve Finans Araştırmaları Dergisi*, 8(4), 660-680. <https://doi.org/10.30784/epfad.1370893>
- Hesarı, S. (2018). *Finansal başarısızlık tahmini: Yapay sinir ağı ve karar ağacı yöntemleri üzerine bir inceleme* (Yayımlanmamış yüksek lisans tezi). Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, İzmir.
- Horak, J., Vrbka, J., & Suler, P. (2020). Support vector machine methods and artificial neural networks used for the development of bankruptcy prediction models and their comparison. *Journal of Risk and Financial Management*, 13(3), 60. <https://doi.org/10.3390/jrfm13030060>
- Iparraguirre-Villanueva, O., & Cabanillas-Carbonell, M. (2024). Predicting business bankruptcy: A comparative analysis with machine learning models. *Journal of Open Innovation: Technology, Market, and Complexity*, 10, 100375. <https://doi.org/10.1016/j.joitmc.2024.100375>
- Larestani, A., Mousavi, S. P., Hadavimoghaddam, F., & Hemmati-Sarapardeh, A. (2022). Predicting formation damage of oil fields due to mineral scaling during water-flooding operations: Gradient boosting decision tree and cascade-forward back-propagation network. *Journal of Petroleum Science and Engineering*, 208, 1-13. <https://doi.org/10.1016/j.petrol.2021.109315>
- Máté, D., Raza, H., & Ahmad, I. (2023). Comparative analysis of machine learning models for bankruptcy prediction in the context of Pakistani companies. *Risks*, 11(10), 176. <https://doi.org/10.3390/risks11100176>
- Michalkova, L., & Ponisciakova, O. (2025). Bankruptcy prediction, financial distress and corporate life cycle: Case study of Central European enterprises. *Administrative Sciences*, 15(2), 63. <https://doi.org/10.3390/admsci15020063>
- Olu-Ajayi, R., Alaka, H., Sulaimon, I., Balogun, H., Wusu, G., Yusuf, W., & Adegoke, M. (2023). Building energy performance prediction: A reliability analysis and evaluation of feature selection methods. *Expert Systems With Applications*, 225, 120109. <https://doi.org/10.1016/j.eswa.2023.120109>

- Özparlak, G., & Özdemir Dilidüzgün, M. (2022). Corporate bankruptcy prediction using machine learning methods: The case of the USA. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 18(4), 1007-1031.
<https://doi.org/10.17130/ijmeh.1079688>
- Rao, H., Shi, X., Rodrigue, A. K., Feng, J., Xia, Y., Elhoseny, M., Yuan, X., & Gu, L. (2019). Feature selection based on artificial bee colony and gradient boosting decision tree. *Applied Soft Computing Journal*, 74, 634-642. <https://doi.org/10.1016/j.asoc.2018.10.036>
- Soydaş, Ş. S. (2021). *İşletmelerde finansal başarısızlığın makine öğrenme yöntemleri ve Altman z-skoru ile tahmin edilmesi* (Yayımlanmamış doktora tezi). Gümüşhane Üniversitesi, Lisansüstü Eğitim Enstitüsü, Gümüşhane.
- Wang, R., Lu, S., & Li, Q. (2019). Multi-criteria comprehensive study on predictive algorithm of hourly heating energy consumption for residential buildings. *Sustainable Cities and Society*, 49, 101623.
<https://doi.org/10.1016/j.scs.2019.101623>
- Wang, Z., Wang, Y., Zeng, R., Srinivasan, R. S., & Ahrentzen, S. (2018). Random Forest based hourly building energy prediction. *Energy & Buildings*, 171, 11-27. <https://doi.org/10.1016/j.enbuild.2018.04.008>
- Xu, X., & Wang, Y. (2009). Financial failure prediction using efficiency as a predictor. *Expert Systems with Applications*, 36(1), 366-373.
<https://doi.org/10.1016/j.eswa.2007.09.040>
- Yaman, S., & Korkmaz, T. (2021). Finansal başarısızlık modellerinin çalışma sermayesi yatırım ve finansman politikaları doğrultusunda incelenmesi: BİST’de karşılaştırmalı bir uygulama. *Gaziantep Üniversitesi Sosyal Bilimler Dergisi*, 20(2), 591-610. <https://doi.org/10.21547/jss.857946>
- Yapa, K., & Coşkun, M. (2024). Sektöre özgü finansal başarısızlık öngörü modeli: Tarım, Orman ve Balıkçılık sektörü. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 19(2), 351-377.
<https://doi.org/10.17153/oguibf.1353967>
- Yürük, M. F., & Ekşi, İ. H. (2019). Yapay zeka yöntemleri ile işletmelerin finansal başarısızlığının tahmin edilmesi: BİST imalat sektörü uygulaması. *Mukaddime*, 10(1), 393-422. <https://doi.org/10.19059/mukaddime.533151>
- Zeytinoglu, E., & Akarım, Y. D. (2013). Financial failure prediction using financial ratios: An empirical application on İstanbul stock exchange. *Journal of Applied Finance & Banking*, 3(3), 107-116.
- Zizi, Y., Oudgou, M., & El Moudden, A. (2020). Determinants and predictors of SMEs’ financial failure: A logistic regression approach. *Risks*, 8(4), 107. <https://doi.org/10.3390/risks8040107>