

Geliş Tarihi:

06.09.2021

Kabul Tarihi:

27.03.2022

Yayımlanma Tarihi:

15.06.2022

Kaynakça Gösterimi: Terzi, S. (2022). İşletmelerin sürekliliğinin değerlendirilmesinde makine öğrenme algoritmalarının kullanımı: Türkiye örneği. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 21(43), 111-132. doi: 10.46928/iticusbe.991788

## İŞLETMELERİN SÜREKLİLİĞİNİN DEĞERLENDİRİLMESİNDE MAKİNE ÖĞRENME ALGORİTMALARININ KULLANIMI: TÜRKİYE ÖRNEĞİ

*Araştırma*

Serkan Terzi 

Sorumlu Yazar (Correspondence)

Çankırı Karatekin Üniversitesi

[serkanterzi@karatekin.edu.tr](mailto:serkanterzi@karatekin.edu.tr)

Serkan Terzi, Çankırı Karatekin Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Muhasebe ve Finansman Anabilim Dalında doçenttir. Muhasebe ve denetim alanında ders vermekte ve bu alanlarda araştırmalar yayınlamaktadır.

# İŞLETMELERİN SÜREKLİLİĞİNİN DEĞERLENDİRİLMESİNDE MAKİNE ÖĞRENME ALGORİTMALARININ KULLANIMI: TÜRKİYE ÖRNEĞİ

Serkan Terzi  
[serkanterzi@karatekin.edu.tr](mailto:serkanterzi@karatekin.edu.tr)

## Özet

**Amaç:** Bu çalışmanın amacı, işletmelerin sürekliliğinin değerlendirilmesi amacıyla makine öğrenme algoritmalarının kullanımınıdır. Bunun için Borsa İstanbul'da 2010-2019 yılları arasında kesintisiz işlem gören 136 şirketin verileri kullanılmıştır. Çalışmaya verilerine ulaşamayan veya taksonomisi farklı şirketler dahil edilmemiştir.

**Yaklaşım:** Çalışmada yapay sinir ağları, karar ağacı, destek vektör makineleri, rassal orman, k-en yakın komşular sınıflandırma, lojistik regresyon ve gaussian naive bayes algoritmaları kullanılmıştır. Çalışmada kullanılan yapay sinir ağları ile destek vektör makineleri kara kutu olarak çalışmaktadır. Çalışmada kullanılan diğerler algoritmalar kural bazlıdır. Yöntemlerin uygulamasında sınıf dengeli 10 kat çapraz doğrulama yöntemi kullanılmıştır.

**Bulgular:** Yapılan analiz sonucunda karar ağacı ve rassal orman algoritmalarının genel başarı oranları %91,2 ve %91,1, Tip 1 hatası %7,1 ve %7,6, Tip 2 hatası ise %13,2 ve %12,2 olarak tespit edilmiştir. Ayrıca, süreklilik değerlendirmesinde aktif karlılık oranı, birikmiş karlar/toplam aktif oranı, finansal kaldıraç oranı, nakit akış tutarının toplam yükümlülük içindeki oranı ile cari oran önemli değişkenler olarak belirlenmiştir.

**Özgünlük:** Literatürde işletmelerin sürekliliğinin değerlendirilmesine yönelik çok sayıda yöntem kullanılmıştır. Ancak son yıllarda makine öğrenmeleri ön plana çıkmaktadır. Türkiye'de ise işletmelerin sürekliliğinin değerlendirilmesinde makine algoritmalarıyla yapılan çalışma sayısı çok azdır. Bu çalışmada en çok kullanılan algoritmalar birlikte uygulanmıştır. Böylelikle en başarılı algoritmalar tespit edilmiştir.

**Anahtar Kelimeler:** Süreklilik, Makine Öğrenme Algoritmaları, Borsa İstanbul, Türkiye

**JEL Sınıflandırması:** M41

# USING MACHINE LEARNING ALGORITHMS TO GOING CONCERN ASSESSMENT: EVIDENCE FROM TURKEY

## Abstract

**Purpose:** The purpose of this study is the use of machine learning algorithms to evaluate the continuity of businesses. For this purpose, the data derived from the 136 companies constantly listed in Borsa Istanbul between the years 2010-2019 are used. Companies whose data could not be accessed or with different taxonomy were not included in the study.

**Approach:** Artificial neural networks, decision tree, support vector machines, random forest, k-nearest neighbor classification, logistic regression and gaussian naive bayes algorithms were used in the study. The artificial neural networks and support vector machines used in the study work as black boxes. Other algorithms used in the study are rule-based. Class balanced 10-fold cross validation method was used in the application of the methods.

**Findings:** As a result of the analysis, the overall success rates of decision tree and random forest algorithms were determined as 91.2% and 91.1%, Type 1 error 7.1% and 7.6%, Type 2 error 13.2% and 12.2%. In addition, return on assets ratio, ratio of retained earnings to total assets, financial leverage ratio, ratio of cash flow amount to total liability and current ratio variables were determined as important variables to evaluate the continuity of businesses.

**Originality:** Numerous methods have been used in the literature to evaluate the continuity of businesses. However, in recent years, machine learning has come to the fore. In Turkey, the number of studies conducted with machine algorithms in the evaluation of the continuity of businesses is very few. In this study, the most used algorithms were applied together. Thus, the most successful algorithms were determined.

**Keywords:** Continuity, Machine Learning Algorithms, Borsa Istanbul, Turkey

**JEL Classification:** M41

## GİRİŞ

İşletmelerin finansal tablolarına ilişkin sayısal bilgiler, finansal durumu ve faaliyet sonuçlarını kapsamaktadır. Denetçi raporu ise bu bilgiye kalitatif boyut eklemektedir. Şöyle ki, denetim faaliyeti finansal tablo hazırlayıcıları ile kullanıcıları arasında bir köprü kurmaktadır (Altman ve McGough, 1974, s.50).

Finansal tabloların hazırlanmasındaki en temel amaç ise, finansal tablo kullanıcılarının alacakları kararlarda yardımcı olmaktır. Bu amaç için denetçi, köprü görevi görmektedir. Ayrıca eğer finansal tablo tarihinden sonraki olayların belirsizliği finansal tablolardan elde edilen bilginin kullanılabilirliğini azaltıyorsa, denetçinin bu belirsizliği finansal tablo kullanıcılarının dikkatine sunma sorumluluğu vardır. Bu sorumluluk, işletmenin faaliyetlerini gelecekte de sürdürme kabiliyetinin olup olmadığına yönelik değerlendirmedir (Altman ve McGough, 1974, s.50). Nitekim Bağımsız Denetim Standartları, denetçinin her denetimde müşteri işletmenin sürekliliğini devam ettirme kabiliyeti hakkında ciddi şüphe olup olmadığını değerlendirmesini gerektirir. Dolayısıyla da denetçinin, müşteri işletmenin sürekliliğini devam ettirme kabiliyetine ilişkin ciddi şüphe olup olmadığını değerlendirmesi gerekmektedir (Martens vd., 2008, s.765).

İşletmelerin gelecek faaliyetlerine yönelik sürekliliğinin değerlendirilmesine yönelik muhakemeler, sadece denetçiler açısından değil, işletmelerin yöneticileri ile finansal tabloları kullanan yatırımcılar, finansal analistler ve çalışanlar başta olmak üzere çok sayıda finansal tablolardan yararlananları da ilgilendirmektedir (Moradi vd., 2012, s.38).

Denetçinin müşteri işletmenin sürekliliğine yönelik değerlendirmeleri bazı önemli sorunları da içermektedir. Şöyle ki, bir işletmenin tasfiyesi, ciddi likidite sorunları veya faaliyetlerini sürdürme konusunda ciddi şüpheler varsa o işletme ile ilgili bir muhakemede bulunulması gerekmektedir (Altman ve McGough, 1974, s.50). Bu değerlendirmeler, niceliksel bazı verileri içerdiği gibi, nicel olmayan değerlendirmeleri de içermektedir. Bu yönüyle denetçilerin işletmelerin sürekliliğine ilişkin değerlendirmeleri, öznel ve geleceğe yönelik olduğundan eleştiri konusu da yapılmaktadır (Koh & Tan, 1999, s.211). Bu nedenle de işletmelerin gelecek faaliyetlerine yönelik değerlendirmeler, denetim mesleği ve düzenleyici kurumlar açısından da her zaman tartışmalı bir konu olmuştur. Bu eleştirilerin odak noktası ise, işletmelerin gelecekte olası başarısızlıkları konusunda yeterli düzeyde erken uyarı sağlamamaları yer almaktadır (Carey vd., 2008, s.61).

Bir işletmenin geleceğe yönelik faaliyetlerinin değerlendirilmesi yürütülen denetimin ana amacı olmasa da, önceden bir süreklilik ile ilgili raporlama yapılmayan işletmelerin iflas etmesi veya batması genellikle halk tarafından denetim ile ilgili raporlama başarısızlığı olarak görülmektedir (Martens vd., 2008, s.766). Özellikle Amerika'da yaşanan Enron skandalından sonra işletmelerin sürekliliğine yönelik değerlendirilmeler denetçi raporlarında öncelikli hale gelmiştir. Hazırlanmış olan bazı denetçi raporlarında işletmelerin faaliyetlerinin süreklilikleriyle ilgili uyarıda

bulunulmaması yani süreklilikle ilgili herhangi bir sıkıntı tespiti yapılmamasına rağmen bu işletmeler, iflas etmiş veya iflas riski ile karşı karşıya gelmiştir (Carey vd., 2008, s.61, McKeown vd., 1991, s.1).

Denetçilerin işletmelerin sürekliliğine yönelik değerlendirmeleri eleştiri konusu yapılmış olsa da finansal tablo kullanıcıları ve sermaye piyasaları açısından önemlidir. Denetçi, yürütmüş olduğu denetim faaliyeti sonucunda önemli şüphenin bulunduğuna karar verirse, hazırlayacağı denetçi raporunda görüş paragrafından sonra açıklayıcı bir paragraf eklemektedir (Martens vd., 2008, s.766).

Sermaye piyasalarının etkin bir şekilde işleyebilmesi için, işletmelerinin faaliyetlerinin sürekli olması ve yatırımcılar ile finansal tablo arasında güven bağının kurulması gerekmektedir. Bu nedenle de denetçilere işletmelerin sürekliliğine yönelik değerlendirme konusunda sorumluluk verilmiştir. Bu sorumluluk, sermaye piyasalarına olan güvene de etki etmektedir. Şöyle ki, 2007 yılında başlayan küresel finansal kriz ile birlikte, şirket başarısızlıklarında da önemli artışlar ortaya çıkmış ve finansal açıdan sıkıntı içinde olan işletmelerle ilgili denetçi raporlarına yeniden ilgi oluşmuştur. Bu ilgi, 2007 ve 2008 yıllarında yaşanan likidite sıkıntısı nedeniyle işletmelerin karşılaştıkları risklerin ortaya konması ve olası sorunlar için denetçilerin görüşleri vasıtasıyla uyarıda bulunmalarını kapsamaktadır (Carson vd., 2013, s.353-354).

İşletmelerin sürekliliklerine yönelik değerlendirme, denetçi açısından da kolaylıkla tespit edilebilecek bir konu değildir. Bu nedenle denetçinin uzmanlığı ve mesleki yargıları ön plana çıkmaktadır (Louwers, 1998, s.144). Bu durum, denetçi tarafından süreklilikle ilgili değerlendirme yapılmasında işletmenin finansal tablolarından elde edilen nicel bazı verilerin yanında nitel bilgilere de ihtiyaç duyulmasına ve mesleki muhakemenin bir bütün olarak yapılmasını gerektirmektedir. Bu amaçla da literatürde süreklilikle ilgili değerlendirmelerin yapılmasında mesleki muhakemeye yardımcı olabilecek bazı modeller ve algoritmalar yer almıştır.

Bu çalışmanın amacı, işletmelerin gelecekteki faaliyetlerinin sürekliliğine yönelik olarak, literatürde sıklıkla yer verilen makine öğrenme algoritmalarının kullanımı ve bu algoritmaların başarı oranlarının tespiti ile birbirlerine göre avantaj ve dezavantajlarının değerlendirilmesidir.

## **LİTERATÜR**

Literatürde işletmelerini sürekliliklerine yönelik risklerinin belirlenmesi ile ilgili çalışmalar 1976 yılına kadar gitmektedir. 1976 yılından itibaren işletmelerin sürekliliklerine yönelik değerlendirmeler için bazı modeller geliştirilmiştir. Süreklilik değerlendirmesi için geliştirilen bu modeller; işletmenin türüne, seçilen değişkenlere ve çalışmalarda kullanılan yöntemlere göre değişiklik göstermiştir (Bellovary vd., 2007, s.9).

Literatürde işletmelerin sürekliliğinin değerlendirilmesine yönelik çok sayıda çalışma olmasının nedeni, değerlendirmenin niceliksel veriler yanında nicel olmayan veya öznel bazı bilgileri de içeriyor olması ve her yöntemin başarı ve üstün yönlerinin farklılaşmasındandır. Bellovary vd. (2007) yaptığı çalışmada süreklilik riskinin belirlenmesine yönelik literatürde kullanılan yöntemler ve faktörlere

ilişkin çalışma yapmıştır. Yapılan çalışmada kullanılan modellerin doğruluk oranları da verilmiştir. Bu çalışmaya göre çoklu diskriminant analizinin başarı oranı %93, lojit analizlerinin başarı oranı %78 ile %100 arasında, probit analizinin başarı oranı %83 ile %86 arasında, yapay sinir ağlarıyla yapılan çalışmanın başarı oranları %32 ile %100 arasında, hibrit ve uzman sistemlerin başarı oranının %77 ile %92 arasında olduğu tespit edilmiştir (Bellovary vd., 2007, s.13-14).

Literatürde finansal başarısızlığın tahminlenmesine yönelik çalışmalar, süreklilikle ilgili çalışmalardan daha eskiye dayanmaktadır. İşletmelerin finansal açıdan başarısız olup olmadıklarının tahminlenmesine yönelik çalışmalar 1960'lı yıllara kadar uzanmaktadır (Moradi vd., 2012, s.38). 1980'li yıllardan itibaren de lojistik regresyon modeli ağırlıklı kullanılmaya başlamıştır (Martens vd., 2008, s.765).

Literatürde yapılan bazı çalışmalarda süreklilik değerlendirmesinde finansal başarısızlık tahminlenmesine yönelik modeller kullanılmıştır. Örneğin Altman ve McGough (1974) yılında finansal açıdan başarısız işletmeler üzerinde çalışmıştır. Benzer şekilde Altman (1968) tarafından işletmelerin finansal başarısızlık tahminlenmesine yönelik "Z Score" modeli geliştirilmiştir. Yapılan çalışmada modelin %84 oranında doğru tahminleme yaptığı tespit edilmiştir.

Altman ve McGough (1974, s.51) yaptıkları çalışmada işletmelerin süreklilikle ilgili sorunlar yaşamalarına neden olan unsurları şu şekilde açıklamışlardır:

- Finansal problemler - yükümlülüklerin karşılanması/ödenmesindeki zorluklar;
  - Likidite eksikliği - işletmelerin kısa vadeli yükümlülüklerinin dönen varlıklarını aşması,
  - Sermaye eksikliği - işletmelerin sermayelerinin bir kısmını veya tamamını kaybetmeleri (negatif özkaynak),
  - Borç temerrüdü - işletmelerin borç ödeme planlarını karşılayamaması veya kredi sözleşmelerinin ihlal edilmesi,
  - Fon sıkıntısı - İşletmelerin çeşitli sermaye kaynaklarından ek fon elde etme imkânı sınırlı olması veya hiç olmaması.
- Faaliyetlerle ilgili sorunlar - faaliyetlerle ilgili başarısızlıklar;
  - Sürekli faaliyetlerden zararlar - uzun dönem boyunca işletme faaliyetlerinin zararlı sonuçlanması,
  - Gelirin yetersizliği - günlük faaliyetler için gelirlerin yetersiz olması veya operasyonlarda kesintiler olması,
  - Yasal sorunlar - yasal nedenlerden dolayı operasyonel faaliyetlerin kısıtlanması,
  - Faaliyetler üzerindeki zayıf kontroller - tekrarlayan, düzeltilmemiş problemlerle ilgili yetersiz kontroller.

Yukarıda sayılan, işletmelerin süreklilik risklerine yönelik faktörlerin benzerleri Bağımsız Denetim Standartları içerisinde de yer almaktadır. Bu faktörlerin denetçiler tarafından dikkate alınarak işletmelerin gelecek faaliyetleriyle ilgili görüş bildirmeleri gerekmektedir.

Denetçinin süreklilikle ilgili karar vermesinde istatistiksel olarak iki tür hata olasılığı söz konusudur. Bunlar Tip 1 ve Tip 2 hatalarıdır. Tip 1 hatası, süreklilik ile ilgili riski olmayan işletmelerin süreklilik riski varmış gibi değerlendirilmesi iken, Tip 2 hatası, süreklilik ile ilgili riski olan işletmelerin süreklilik riski yokmuş gibi değerlendirilmesidir (Carey vd., 2008, s.62).

Denetçi, Tip 1 hatasını azaltmak için denetim prosedürlerinin kapsam ve zamanlamasını artırabilir. Bu durum denetim faaliyetinin maliyetini artıracaktır. Bunun yanında denetçi görüşü yanlış olarak değiştirildiğinde işletmenin hissedarları, hisseleri satmaya karar verebilir ve bu durum da işletme için maliyetli olabilir. Bu durum da, işletmenin denetçisini değiştirmesine yol açabilir. Buna karşın, Tip 2 hatası ise eksik veya yeterli düzeyde planlanmamış bir denetim faaliyetinin bir sonucunda ortaya çıkabilir. Bu durum ise işletmelerin finansal tablolarında olası hile riskini artırabilir. Bunun yanında Tip 2 hatası, gelecekte olumlu görüş verilmiş işletmelerin olası iflas etmeleri riskinden dolayı, yasal yükümlülüğü de beraberinde getirecektir. Bu durumda denetçiler dava riskleri ile karşı karşıya kalabilir (Lenard vd., 2001, s.2-3). McKeown vd. (1991, s.6) yaptığı çalışmada Tip 1 hatasını %5, Tip 2 hatasını da %54 olarak tespit etmişlerdir. Literatürde yapılan çalışmalarda Tip 1 ve 2 hataları ile ilgili farklı bulgular yer almaktadır. Nitekim Bell & Tabor (1991) yaptıkları çalışmada Tip 1 hatasını %22 ile %55 arasında, Tip 2 hatasını %0 ile %11 arasında bulmuştur. Hataların ortalaması ile %4 ile %12 arasında tespit edilmiştir. Lenard vd. (2001) yaptıkları çalışmada oluşturdukları beş model için Tip 1 hatasını %0 ile %21 arasında, Tip 2 hatasını %4 ile %49 arasında bulmuştur. Oluşturdukları 5 modelin ortalama hata düzeyleri %6 ile %10 arasında tespit edilmiştir.

Literatürde yapılmış olan çalışmalar, işletmelerin sürekliliklerinin değerlendirilmesinin zorlu bazı süreçler içerdiğini göstermektedir. Örneğin Koh & Tan (1999), 86 Birleşik Krallık işletmesi üzerinde 1977 ile 1983 dönemini kapsayan iflas etmiş işletmeler üzerinde bir araştırma yapmışlardır. Yapılan bu çalışmada 21 işletmenin iflas etmelerinden önceki son finansal tablolarında süreklilikle ilgili görüş verildiği tespit edilmiştir. Benzer şekilde Menon ve Schwartz (1986)'ın yaptıkları çalışmada da buna yakın sonuçlar bulunmuştur. Yapılan bu çalışma ABD'de gerçekleştirilmiş ve 147 işletme üzerinde yapılmıştır. Bu çalışmada 147 işletmeden iflas eden işletmelerin sadece 63'ü için süreklilikle ilgili görüş verildiği tespit edilmiştir.

### ***İstatistiksel Modeller***

İşletmelerin gelecek faaliyetlerine yönelik süreklilik değerlendirmelerinde en çok kullanılan istatistiksel modeller çoklu diskriminant analizi, lojit analizi, probit analizleridir (Bellovary vd., 2007, s.11).

İşletme sürekliliği ile ilgili çalışmalardan önce işletmelerin finansal başarısızlığın tahminlenmesine ilişkin çalışmalar yapılmıştır. Bu çalışmalarda 1960 ile 1980'li yıllar arasında daha çok diskriminant analizi yöntemi kullanılmıştır. Diskriminant analizinin sıklıkla kullanılmasının nedeni ise, yöntemin kullanımının kolaylığıdır. Ancak diskriminant analizleri verilerin normallik dağılımını gerektirmektedir. 1980'li yıllardan itibaren de probit ve lojit modellerin (lojistik regresyon) kullanımı

artmıştır (Moradi vd., 2012, s.38). Özellikle de süreklilikle ilgili çok sayıda çalışmada lojistik regresyon yöntemi kullanılmaya başlanmıştır (Martens vd., 2008, s.765). Lojistik regresyon modeli, diskriminant analizi gibi normallik varsayımı gerektirmemektedir.

Literatürde istatistiksel modeller, halka açık işletme verileri kullanılarak işletmelerin sürekliliğinin değerlendirilmesinde kullanılmış ve süreklilik tahmininde çeşitli başarı oranları elde edilmiştir (Lenard vd., 2001, s.2).

Bazı çalışmalarda işletme sürekliliğinin değerlendirilmesinde, denetçinin görüş oluşturmaya yardımcı olmak amacıyla istatistiksel modellerin kullanımı önerilmiştir (Koh ve Tan, 1999, s.211).

### ***Uzman Sistem Modelleri***

1990'lı yıllardan itibaren finansal başarısızlık tahminlemesi ve süreklilikle ilgili çalışmalarda yapay sinir ağları sıklıkla kullanılmaya başlanmıştır. Yapılan birçok çalışmada yapay sinir ağları ile istatistiksel yöntemler karşılaştırılmıştır. Bazı çalışmalarda da yapay sinir ağlarının diskriminant analizi gibi istatistiksel modellere göre daha iyi performans gösterdiği tespit edilmiştir (Moradi vd., 2012, s.38).

Literatürde sınıflandırma amacına yönelik olarak da kullanılabilen veri madenciliği türleri bulunmaktadır. Bunlar için de yaygın bir şekilde kullanılanlar ise C4.5, k-en yakın komşular, yapay sinir ağları ve destek vektör makineleridir (Martens vd. 2008, s.768-769).

Uzman sistem modelleri içerisinde ise sınıflandırma algoritması olarak en çok kullanılan yöntem yapay sinir ağları olmuştur (Moradi vd., 2012, s.39). Yapay sinir ağlarına yönelik yapılan çalışmalarda bu algoritmanın sonuçlarının istatistiksel yöntemlere göre karşılaştırılabilir olduğu ifade edilmektedir. Ayrıca istatistiksel modellerdeki bazı sınırlamaları (kısıtlayıcı varsayımlar gibi) hafifletebilmektedir. Bu nedenle, yapay sinir ağlarının süreklilik değerlendirilmesinde önemli bir potansiyele sahip olduğu ifade edilmiştir (Koh ve Tan, 2012, s.212).

O'Leary & Watkins (1989) denetim alanında uzman sistemlerin kullanımını incelemiştir. Yaptıkları çalışmada denetim faaliyetinin karmaşık ve benzersiz karar verme süreçlerini içerdiği, bu nedenle geliştirilmiş bilgisayar destekli sistemlerin kullanımını açıklamıştır.

### ***Hibrit Sistemler***

Yaşamış olduğumuz dönemde bazı sorunların çözümü için genellikle tek bir yöntemin kullanılması, sorunun çözümü açısından yeterli olmayabilmektedir. Bu nedenle birden fazla yöntemin güçlü yönlerinin birleştirilmesi yoluyla yeni bir yöntemin oluşturulması daha etkin çözüm imkanı sağlayabilmektedir. Birden fazla yöntemin güçlü yönlerinin birleştirilmesi ile oluşan sistemlere hibrit sistem ismi verilmektedir (Lenard vd., 2001, s.4).

Hibrit sistemler, günlük yaşamda birçok sektörde özellikle imalat sanayisinde kullanım alanı bulunmaktadır. Literatürde yapılan bir çalışmada, bir kuyruk ağı modeli ve bir yerel arama



algoritması birleştirilerek yeni bir algoritma geliştirilmiştir. Benzer şekilde esnek üretim sistemleri için çözüm üretmek amacıyla yapay sinir ağları ve bilgi tabanlı bir uzman sistemin entegrasyonu yapılmıştır. Yeni problemlerin çözümü için yukarıdaki gibi yeni sistemlerin entegrasyonu yanında geleneksel sorunların çözümü için de entegrasyon yapılabilmektedir (Lenard vd., 2001, s.4).

## YÖNTEM

### *Araştırmanın Tasarımı*

Bu çalışmanın temel amacı, denetçilerin süreklilik göstergesi olabilecek ve literatürde önceki çalışmalarda yer verilen çeşitli değişkenler ve yöntemler kullanılarak tahmin modellemeleri oluşturulması ve bu modellerin performanslarının karşılaştırılmasıdır. Bu amaçla literatürde kullanılmış olan makine öğrenme algoritmaları esas alınmıştır.

### *Veri Seti Seçimi ve Değişkenlerin Belirlenmesi*

Bu çalışmada Borsa İstanbul'da sürekli işlem gören 136 şirketin 2010-2019 yıllarına ilişkin finansal ve finansal olmayan verileri esas alınmıştır. Analize taksonomisi farklı olan finansal kuruluşlar ile 10 yıllık kesintisiz verisi olmayan şirketler dahil edilmemiştir. Analize toplam 1.360 gözlem dahil edilmiştir. Bu gözlemlerden 410'u işletme sürekliliği açısından riskli değerlendirilmiş, 950'si ise süreklilik bakımından riskli olmayan olarak değerlendirilmiştir.

Literatürde algoritmalarla yapılan sınıflandırma çalışmalarında, veri setindeki gözlemlerin ikili grup olarak birbirine yakın olduğu çalışmalar olduğu gibi, dengeli olmayan veri setleri de kullanılmıştır. Dengeli veri setinde, süreklilik riski içeren gözlemler ile içermeyen gözlemler eşit düzeyde analize dahil edilmektedir. Buna karşın dengeli olmayan veri setinde ise gözlemler eşit oranlı olmamaktadır (Martens vd. 2008, s.766-777). Bu çalışmada 10 yıl boyunca sürekli işlem gören ve taksonomisi aynı olan tüm şirketler analize dahil edildiğinden, oluşturulacak modellerin gerçek durumu yansıtması amacıyla veri seti olduğu gibi analize dahil edilmiştir. Bir gurubun diğer gruba göre ağır basmasının önlenmesi amacıyla veri seti 10 eşit parçaya bölünmüş ve her denemede eğitim seti ile test seti için seçilen değişkenler rastgele olarak ve birbirinden farklı olarak seçilmiştir.

Bu çalışmada daha önce literatürde kullanılmış olan değişkenler seçilmiştir. Çalışmada bağımlı değişken olarak işletmelerin sürekliliğine yönelik değerlendirme (GC) esas alınmıştır. Çalışmada kullanılan gözlemlerin süreklilik açısından risk içerip içermediklerinin değerlendirilmesinde aşağıdaki kriterler kullanılmış olup, bu kriterlerin en az üçünü karşılayan gözlemlerde süreklilik varsayımının zedelendiği kabul edilmiştir.

- Dönem zararı (Harris & Harris, 1989; Marten vd., 2008; Carey vd., 2008; Carson vd., 2013; Gallizo ve Saladrigues, 2016),
- Negatif özkaynak veya sermaye kaybı (Carey vd., 2008, Marten vd., 2008),
- Geçmiş yıl zararı (Marten vd., 2008),
- Faaliyet zararı (Marten vd., 2008),

- Negatif çalışma sermayesi (Harris ve Harris, 1989; Marten vd., 2008; Carey vd., 2008),
- Negatif işletme faaliyetlerinden nakit akışı (Harris ve Harris, 1989; Marten vd., 2008),
- Denetçi görüşünde süreklilikle ilgili açıklama olup olmaması (Carey vd., 2008; Chen ve Church, 1992; Koh ve Tan, 1999; Menon ve Schwartz, 1987),
- Z değeri (Altman ve McGough, 1974; Gallizo ve Saladrigues, 2016; Haron vd., 2009).

Literatürde yapılan çok sayıda çalışmada finansal açıdan başarısızlık ile süreklilik değerlendirilmesi arasındaki ilişki incelenmiş (Carson vd., 2013; Mutchler, 1984) ve aralarında ilişki olduğu tespit edilmiştir. Bu çalışmada gözlemlerin süreklilik riski içerip içermediğine ilişkin değerlendirme kriterlerine “Z” ölçütü de dahil edilmiştir. Bunun yanında yapılan çalışmalarda seçilen bağımsız değişkenler farklılık göstermektedir. Bu çalışmada literatürde sıklıkla kullanılan değişkenler analize dahil edilmiştir.

Yapılan çalışmalarda genellikle işletme sürekliliğinin değerlendirilmesinde süreklilik riski taşıyan şirketlerin daha az karlı veya zararda oldukları (Mutchler, 1985; Altman & McGough, 1974; Koh ve Killough, 1990; Menon ve Schwartz, 1987; Carson vd., 2013; Gallizo ve Saladrigues, 2016), finansal kaldıraç oranlarının yüksek olduğu (Altman ve McGough, 1974; Mutchler, 1985; Carson vd., 2013; Gallizo ve Saladrigues, 2016), likidite düzeylerinin düşük olduğu (Mutchler, 1985; Menon ve Schwartz 1987; Koh ve Killough 1990; Carson vd., 2013; Gallizo ve Saladrigues, 2016) ve küçük ölçekli oldukları (McKeown vd., 1991; Carson vd., 2013; Gallizo ve Saladrigues, 2016) tespit edilmiştir.

Bağımsız Denetim Standartlarında süreklilik riskine yönelik değerlendirmeye yönelik faktörler arasında negatif trend, faaliyet zararları, yetersiz çalışma sermayesi, negatif nakit akışı, olumsuz yönde finansal rasyolar sayılmıştır. Bunların yanında bazı çalışmalarda yüksek düzeyde alacak ve stok düzeyinin de şirketler açısından risk içerdiği ifade edilmiştir (Bell ve Tablo, 1991, s.352).

Yapılan bir çalışmada yatırım karlılığı (ROA) ile şirketlerin finansal başarısızlığı arasında negatif korelasyon tespit etmiştir. Buna göre ROA düzeyi arttıkça, finansal açıdan başarısızlık riski azalmaktadır (Bell ve Tablo, 1991, s.354).

Tablo 1’de çalışmada kullanılan değişkenler ile bu değişkenlerin literatürde hangi çalışmalarda kullanıldığı açıklanmıştır.

**Tablo 1.** Seçilen Bağımsız Değişkenler

Bağımsız değişkenler	Literatür
Bilanço tarihi ile denetim raporu arasındaki süre (SURE)	McKeown vd. (1991); Louwers (1998); Gallizo & Saladrignes (2016)
Şirket büyüklüğü (toplam aktifin doğal algoritması) (LNTA)	Raghunandan & Rama (1995); Geiger & Raghunandan (2002); Carey vd. (2008); Chen & Church (1992); Gallizo & Saladrignes (2016)
Alacaklar/toplam aktif (ALTA)	Ruiz-Barbadillo vd. (2004); Salehi & Fard (2013)
Stoklar/toplam aktif (STTA)	Ruiz-Barbadillo vd. (2004); Salehi & Fard (2013)
Cari oran (CARO)	Mutchler (1985); Chen & Church (1992); Raghunandan & Rama (1995); Goodman vd. (1995); Lenard vd. (2001); Kuruppu vd. (2003); Carson vd. (2013); Gallizo & Saladrignes (2016)
Finansal kaldıraç oranı (FIKL)	McKeown vd. (1991); Mutchler (1984); Mutchler (1985); Lenard vd. (2001); Koh & Tan (1999), Bellovary vd. (2007), Altman & McGough 1974; Carson vd. (2013); Menon & Schwartz (1987)
Net kar/toplam aktif (ROA)	Koh & Tan (1999); Bellovary vd. (2007); Gallizo & Saladrignes (2016); Menon & Schwartz (1987)
Birikmiş karlar/toplam aktif (BKTA)	Koh & Tan (1999); Bellovary vd. (2007); Menon & Schwartz (1987)
Uzun vadeli yükümlülükler/toplam aktif (UYTA)	Lenard vd. (2001); Bellovary vd. (2007); Chen & Church (1992); Mutchler (1985)
Vergi öncesi kar-zarar/net satışlar (VKHA)	Lenard vd. (2001); Bellovary vd. (2007); Chen & Church (1992); Mutchler (1985)
Nakit akış tutarı/toplam yükümlülük (NATY)	Bellovary vd. (2007); Carson vd. (2013); Chen & Church (1992); Mutchler (1985); Levitan & Knoblett (1985); Menon & Schwartz (1987)
Dört büyük denetim firması	Carey vd. (2008); Gallizo & Saladrignes (2016); Haron vd. (2009)
Özkaynak/toplam yükümlülük (NAKF)	Carson vd. (2013); Mutchler (1985)

### Yöntem

Literatürde yapılan çalışmalar öncelikle istatistiksel bazı yöntemleri esas almış ve bunlar içerisinde de lojistik regresyon modeli ön plana çıkmıştır. Bu nedenle bu çalışmada da lojistik regresyon modeline yer verilmiştir. Ancak bu modelin kullanımı kolay olmakla birlikte açıklayıcılığı çok yüksek değildir. Bu nedenle de literatürde bu eksikliği gidermek için sınıflandırma modelleri kullanılmıştır. Bunlar içerisinde bazıları kara kutu denen bir yapı ile (örneğin yapay sinir ağları) çalışırken, bazıları da kural bazlı (örneğin karar ağacı) bir algoritma ile çalışmaktadır. Bu çalışmada yapay sinir ağları, karar ağacı, destek vektör makineleri, random forests (rassal orman), k-en yakın komşular, lojistik regresyon ve gaussian naive bayes algoritmaları kullanılmıştır. Kullanılan bu yöntemlerin ürettiği kurallar veya istatistiksel olarak etkinliği tespit edilmiş olan değişkenler, uygulamada kullanılarak denetçilerin ve işletmelerin süreklilik değerlendirmesine yardımcı olabilecektir. Özellikle denetçiler açısından denetim görüşü verilmeden önce bu kural ve değişkenler üzerinden müşteri işletmenin nihai olarak süreklilik değerlendirmesine kıyaslama imkanı sağlayacaktır. Yöntemlerin uygulamasında Python'ın scikit-learn açık kaynaklı makine öğrenmesi

kütüphanesi kullanılmıştır. Ayrıca bütün modellerde sckit-learn kütüphanesinin varsayılan parametreleri kullanılmıştır.

Çalışmada tüm yöntemler için sınıf dengeli 10 kat çapraz doğrulama yöntemi kullanılmıştır. 10 kat çapraz doğrulama yönteminde analize dahil edilen gözlem verileri 10 parçaya ayrılmıştır. Yapılan bu ayrımların 9 parçası eğitim seti olarak, 1 parçası da test seti olarak kullanılmıştır. Bu işlem her yöntem için 10 kez tekrarlanmıştır. Böylelikle her denemede seçilen 9 parça eğitim seti ile 1 parça test seti birbirleri ile aynı olmayacak yani benzer olmayacak şekilde seçilmiştir. Bu işlemin yapılmasının temel nedeni ise, kullanılan makine öğrenme tabanlı algoritmaların veri seti üzerindeki performansının daha doğru olarak tespit edilmesinin sağlanmaya çalışılmasıdır.

Veri seti, seçilen yöntemlerde kullanılmadan önce standardize edilmiştir. Bu amaçla eğitim seti kullanılarak aşağıdaki formül yardımıyla uygunluk parametreleri belirlenmiştir. Eğitim ve test seti bu parametrelere göre normalize edilmiştir. Bu işlemin yapılmasıyla veri seti normal dağılıma dönüştürülmekte olup, ortalama 0 ve birim varyanslı gaussian dağılımına dönüşmektedir. Her kat doğrulama yönteminde eğitim ve test seti kombinasyonu değiştiğinden bu işlem her bir kat doğrulama için tekrar edilmektedir.

$$z = (x - u) / s$$

s: eğitim setinin standart sapma

u: eğitim setinin ortalaması

x: değişkenin değeri

## BULGULAR

### *Yöntemlerin Performansları*

Yapılan analiz neticesinde kullanılmış olan yöntemlerin süreklilik riski olan gözlemlerin doğru bir şekilde sınıflandırılma açısından başarı oranları (ACC-Accuracy) aşağıdaki gibi tespit edilmiştir:

**Tablo 2.** Yöntemlerin Performansları

Performanslar – Başarı Oranları			
Yöntemler	En düşük	En yüksek	Ortalama
Destek vektör makineleri	%82	%89	%87
Rassal orman algoritması	%86	%93	%91
K-en yakın komşular algoritması	%83	%91	%87
Lojistik regresyon	%83	%92	%87
Gaussian naive bayes algoritması	%65	%89	%80
Karar ağacı	%84	%95	%91
Yapay sinir ağları	%88	%93	%90

Yukarıdaki tablo incelendiğinde en yüksek başarı oranı ortalama olarak karar ağacı algoritmasında elde edilmiştir. Kara kutu mantığıyla çalışan yapay sinir ağları ile destek vektör makinelerinin başarı

oranları ise ortalamanın üstünde yer almaktadır. Özellikle de yapay sinir ağlarının başarı oranı yüksek düzeyde görülmektedir. Ancak bu algoritmaların açıklayıcılığı ve anlaşılabilirliği düşüktür. Bu nedenle de hangi değişkenlerin veya kuralın bu başarı oranının elde edilmesinde baskın olarak etkili olduğu tespit edilememektedir. Bunun yanında literatürde bunun gibi kara kutu mantığıyla çalışan algoritmaların sonuçlarının daha açıklanabilir ve anlaşılabilir olmasına yönelik geliştirmeler ve algoritmalar da kullanılmaktadır.

Yöntemlerin uygulamasında veri seti 10 kat çapraz doğrulama yöntemi uygulandığından her algoritma içinde 10'lu başarı oranı ile Tip 1 ve Tip 2 hataları elde edilmiştir. Algoritmaların Tip 1 ve Tip 2 hataları aşağıdaki tabloda özetlenmiştir:


**Tablo 3.** Yöntemlerin Performansları

Yöntemler	Tip 1 hatası			Tip 2 hatası		
	En düşük	En yüksek	Ortalama	En düşük	En yüksek	Ortalama
Destek vektör makineleri	% 7	% 15	% 12	% 7	% 24	% 16
Rassal orman algoritması	% 5	% 13	% 8	% 5	% 22	% 12
K-en yakın komşular algoritması	% 3	% 11	% 6	% 17	% 41	% 28
Lojistik regresyon	% 8	% 16	% 13	% 7	% 24	% 14
Gaussian naïve bayes algoritması	% 12	% 45	% 22	% 7	% 24	% 14
Karar ağacı	% 3	% 16	% 7	% 5	% 20	% 13
Yapay sinir ağları	% 3	% 7	% 5	% 10	% 32	% 20

Yöntemler içerisinde yapay sinir ağlarının süreklilik riski olmadığı halde varmış gibi yapmış olduğu sınıflandırma hatası en düşük olmakla birlikte, Tip 2 hatasında yükselme olduğu görülmektedir. Benzer durum k-en yakın komşular algoritması için de geçerlidir. Tip 1 hatası, ne kadar düşürmek istenirse, literatürde de ifade edildiği gibi, Tip 2 hatası artmaktadır. Bu bulgular incelendiğinde karar ağacı ve rassal orman ağacı algoritmalarının başarı oranlarının yüksek olması, buna karşın Tip 1 ve Tip 2 hatalarının diğerlerine göre makul seviyede olması nedeniyle yapılan analizde ön plana çıktığı söylenebilir.

### ***Destek Vektör Makineleri***

Destek vektör makineleri algoritmasında yapılan testlerde en yüksek başarı oranı %89 olarak hesaplanan 3 test tespit edilmiştir. Bunlar içinde Tip 1 ve Tip 2 hatası ortalaması en düşük olan %10,0 olarak belirlenmiştir. Tip 1 ve Tip 2 hatası ortalaması en düşük olan testte etki eden değişkenler aşağıdaki grafikte sunulmuştur:

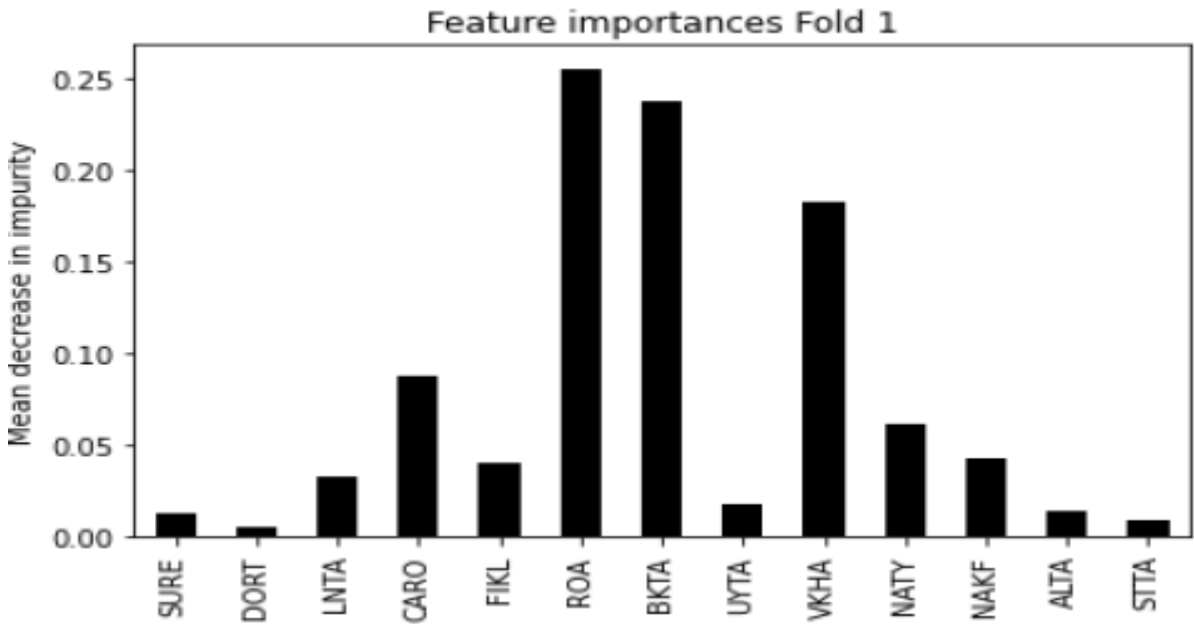


Şekil 1. Destek Vektör Makineleri Algoritmasına Etki Eden Önemli Değişkenler

Destek vektör makineleri algoritmasında başarı oranına etki eden değişkenlerden ROA, BKTA, ALTA, FIKL ve NATY ön plana çıkmıştır.

#### ***Random Forests (Rassal Orman)***

Rassal orman algoritmasında yapılan testlerde en yüksek başarı oranı %93 olarak hesaplanan 4 test tespit edilmiştir. Bunlar içinde Tip 1 ve Tip 2 hatası ortalaması en düşük olan %6,1 olarak belirlenmiştir. Tip 1 ve Tip 2 hatası ortalaması en düşük olan testte etki eden değişkenler aşağıdaki grafikte sunulmuştur:

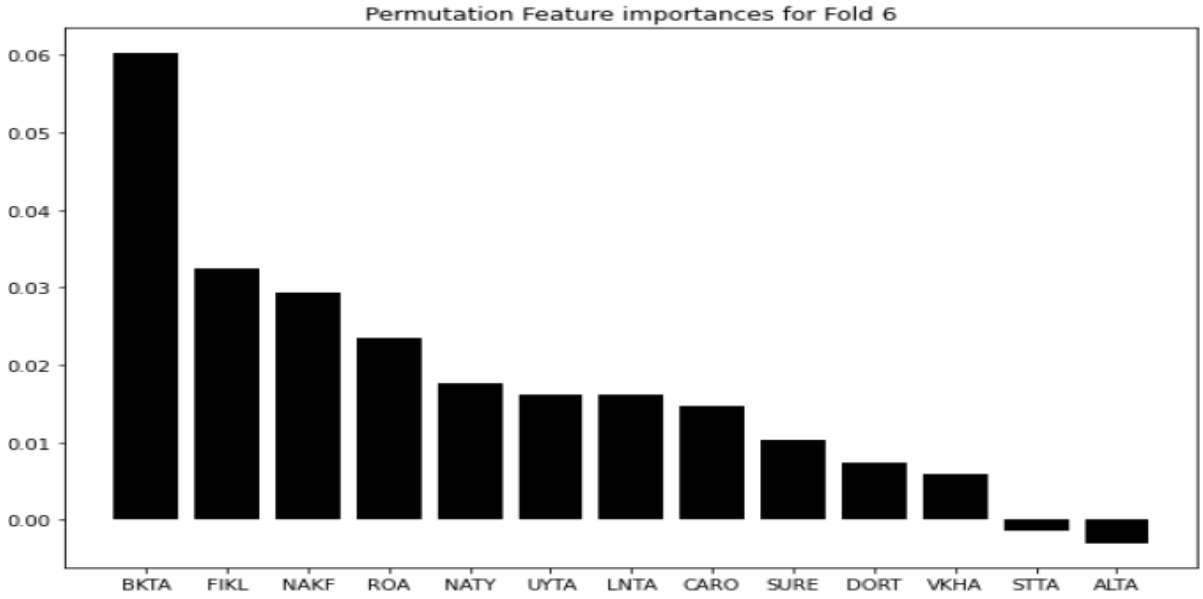


Şekil 2. Rassal Orman Algoritmasına Etki Eden Önemli Değişkenler

Rassal orman algoritmasında başarı oranına etki eden değişkenlerden ROA, BKTA, VKHA, CARO ve NATY ön plana çıkmıştır.

### ***K-En Yakın Komşular Sınıflandırma***

K-en yakın komşular sınıflandırma algoritmasında yapılan testlerde en yüksek başarı oranı %91 olarak hesaplanan 1 test tespit edilmiştir. Bu testin Tip 1 ve Tip 2 hatası ortalaması %11,9 olarak belirlenmiştir. Bu teste etki eden değişkenler aşağıdaki grafikte sunulmuştur:




**Şekil 3.** K-En Yakın Komşular Sınıflandırma Algoritmasına Etki Eden Önemli Değişkenler

K-en yakın komşular sınıflandırma algoritmasında başarı oranına etki eden değişkenlerden BKTA, FIKL, NAKF ve ROA ön plana çıkmıştır.

### ***Lojistik Regresyon***

Lojistik regresyon algoritmasında yapılan testlerde en yüksek başarı oranı %92 olarak hesaplanan 1 test tespit edilmiştir. Bu testin Tip 1 ve Tip 2 hatası ortalaması %7,9 olarak belirlenmiştir. Bu teste etki eden değişkenler aşağıdaki grafikte sunulmuştur:

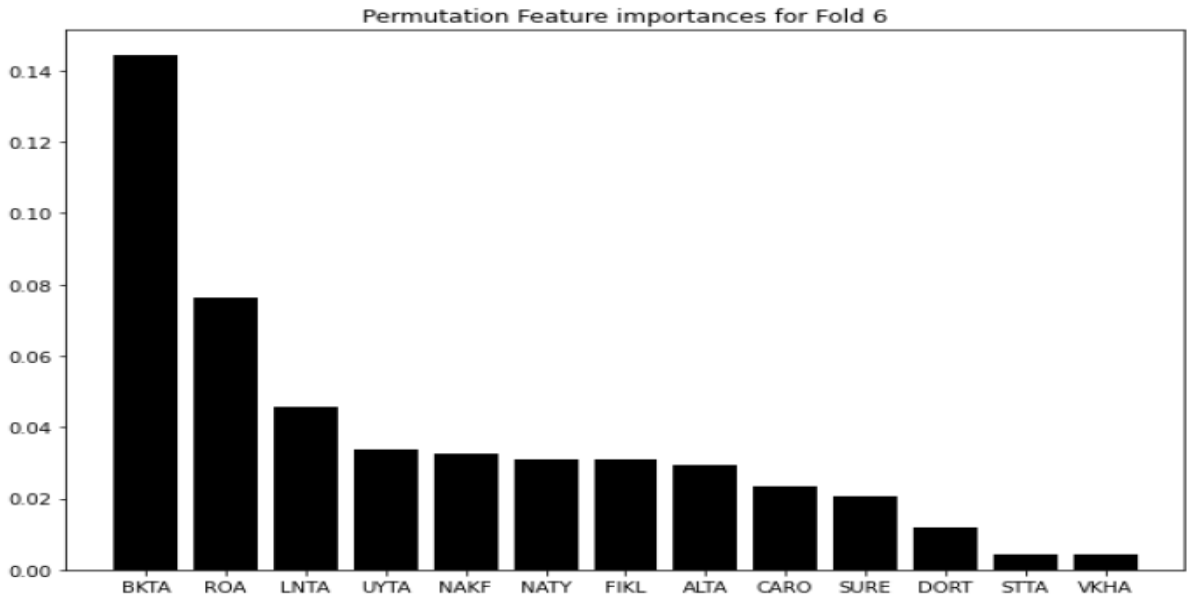


**Şekil 4.** Lojistik Regresyon Algoritmasına Etki Eden Önemli Değişkenler

Lojistik regresyon algoritmasında başarı oranına etki eden değişkenlerden ROA, BKTA, FIKL ve NATY ön plana çıkmıştır.

#### ***Gaussian Naive Bayes***

Gaussian naive bayes algoritmasında yapılan testlerde en yüksek başarı oranı %89 olarak hesaplanan 1 test tespit edilmiştir. Bu testin Tip 1 ve Tip 2 hatası ortalaması %10,7 olarak belirlenmiştir. Bu testte etki eden değişkenler aşağıdaki grafikte sunulmuştur:




**Şekil 5.** Gaussian Naive Bayes Algoritmasına Etki Eden Önemli Değişkenler

Gaussian naive bayes algoritmasında başarı oranına etki eden değişkenlerden BKTA, ROA, LNTA ve UYTA ön plana çıkmıştır.



### **Karar Ağaçları**

Bu çalışmada, scikit-learn kütüphanesinde yer alan karar ağacı sınıflandırıcısı kullanılmıştır. Rastal orman sınıflandırıcı ilgili tabloda karar ağacından farklı olarak raporlanmıştır. Karar ağacı algoritmasında yapılan testlerde en yüksek başarı oranı %95 olarak hesaplanan 1 test tespit edilmiştir. Bu testin Tip 1 ve Tip 2 hatası ortalaması %5,8 olarak belirlenmiştir. Bu testte etki eden değişkenler aşağıdaki grafikte sunulmuştur:




**Şekil 6.** Karar Ağacı Algoritmasına Etki Eden Önemli Değişkenler

Karar ağacı algoritmasında başarı oranına etki eden değişkenlerden ROA, BKTA, NATY ve CARO ön plana çıkmıştır.

### **Yapay Sinir Ağları**

Yapay sinir ağı algoritmasında yapılan testlerde en yüksek başarı oranı %93 olarak hesaplanan 1 test tespit edilmiştir. Bu testin Tip 1 ve Tip 2 hatası ortalaması %8,9 olarak belirlenmiştir. Bu testte etki eden değişkenler aşağıdaki grafikte sunulmuştur.



**Şekil 7.** Yapay Sinir Ağı Algoritmasına Etki Eden Önemli Değişkenler

Yapay sinir ağı algoritmasında başarı oranına etki eden değişkenlerden ROA, BKTA, FIKL ve UYTA ön plana çıkmıştır.

## SONUÇ, TARTIŞMA VE ÖNERİLER

Bu çalışma, Borsa İstanbul’da işlem gören işletmelerin süreklilik risklerinin makine öğrenme algoritmaları yardımıyla değerlendirilmesi amacıyla yapılmıştır. Elde edilen sonuçların etkinliğinin tespiti için literatürde sıklıkla yer verilen makine öğrenme algoritmaları kullanılmıştır. Elde edilen sonuçlara göre karar ağacı ve rassal orman algoritmalarının başarı oranının diğer algoritmalara ve literatüre göre yeterli olduğu ve işletmelerin süreklilik değerlendirmesinin yapılmasında kullanışlı olacağı tespit edilmiştir. Bunun yanında literatüre göre bu algoritmaların Tip 1 ve 2 hataları da makul düzeydedir.

Yapılan çalışmada kullanılan değişkenler, daha önce süreklilik değerlendirmesinde kullanılmış ve etkinliği tespit edilmiş olan değişkenlerdir. Ancak Borsa İstanbul için seçilmiş olan algoritmalarla yapılan analizlerde aktif karlılık oranı, birikmiş karlar/toplam aktif oranı, finansal kaldıraç oranı, nakit akış tutarının toplam yükümlülük içindeki oranı ile cari oranın en önemli değişkenler oldukları belirlenmiştir. Bu bulgulara göre işletmelerin likidite durumları, nakit akışlarının yönetimi, aktiflerin etkin kullanılıp kullanılmadığı ve buna bağlı olarak karlılık durumları işletmelerin sürekliliği açısından dikkate etmesi gereken hususlar olarak belirlenmiştir. Bu tespitler, Türkiye’de yürürlükte olan düzenleyici kuruluşlar tarafından yayınlanmış düzenlemelerle de uyumludur. Şöyle ki, Türkiye’de işletmelerin sürekliliğinin değerlendirilmesine yönelik olarak Kamu Gözetimi Muhasebe ve Denetim Standartları Kurumu tarafından yayınlanmış olan BDS 570 “İşletmenin Sürekliliği” Standardı yayınlanmış ve bu standardın “Risk Değerlendirme Prosedürleri ve İlgili Faaliyetler” bölümünde süreklilikle ilgili risk faktörleri sıralanmıştır. Bu bulgular, sıralanan bu risk faktörleri ile

de uyumludur. Benzer şekilde Altman ve McGough (1974) tarafından yapılan çalışma ile de uyumlu sonuçlar tespit edilmiştir.

Kural bazlı algoritmalar (rassal orman, karar ağacı gibi), yapay sinir ağları ve SVM gibi kara kutu mantığıyla çalışan yöntemlere göre daha anlaşılabilir ve kullanışlı sonuçlar sunmaktadır. Çünkü bu yöntemde değişkenlerden oluşan kurallar silsilesi sunulmakta ve finansal piyasalarda kullanımı daha uygun olmaktadır. Bununla birlikte geleneksel olarak kullanılan lojistik regresyon gibi liner tabanlı algoritmalar da kara kutu yöntemlerine göre açıklanabilir özelliğe sahiptir. Çünkü bu algoritmada değişkenlerin katsayı değerleri elde edilebilmektedir.

Çalışmada taksonomisi uyumlu olmayan finansal kuruluşlarla verilerine ulaşamayan işletmeler analize dahil edilmemiştir. Bu nedenle çalışmanın sonuçları analize dahil edilmeyen sektörler üzerinde kullanışlı olmayacaktır.

Gelecekte yapılacak çalışmalarda daha uzun dönemli veri setleri üzerinde çalışma yapılması halinde daha yararlı sonuçlar elde edilebilecektir. İşletmelerin süreklilik değerlendirmesi, nicel verilerin yanında bazı nitel değerlendirmeleri de içerdiğinden oluşturulacak modellerde süreklilik üzerinde etkili olan nitel faktörlere de yer verilmesi sonuçların daha doğru bir şekilde genelleştirilmesine imkan sağlayacaktır.

## KAYNAKÇA

- Altman, E.I. & McGough, T.P. (1974). Evaluation of a company as a going concern. *Journal of Accounting, Auditing and Finance*, 6(4), 4-19. <https://www.journalofaccountancy.com/>
- Bell, T.B. & Tablo, R.H. (1991). Empirical analysis of audit uncertainty qualifications. *Journal of Accounting Research*, 29(2), 350-370. <https://doi.org/10.2307/2491053>
- Bellovary, J.L., Giacominio, D.E. & Akers, M.D. (2007). A review of going concern prediction studies: 1976 to present. *Journal of Business & Economics Research*, 5, 9-28. <https://doi.org/10.19030/jber.v5i5.2541>
- Carey, P.J., Geiger, M.A. & O'Connell, B.T. (2008). Costs associated with going-concern-modified audit opinions: an analysis of the Australian audit market. *Abacus*, 44(1), 61-81. <https://doi.org/10.1111/j.1467-6281.2007.00249.x>
- Carson, E., Fargher, N.L., Geiger, M.A., Lennox, C.S., Raghunandan, K. & Willekens, M. (2013). Audit reporting for going-concern uncertainty: a research synthesis. *Auditing: A Journal of Practice & Theory*, 32(1), 353-384. <https://doi.org/10.2308/ajpt-50324>
- Chen, K.C.W. & Church, B.K. (1992). Default on debt obligations and the issuance of going-concern opinions. *Auditing: A Journal of Practice and Theory*, 11(2), 30-50. <https://meridian.allenpress.com/ajpt>
- Gallizo, J.L. & Saladríguez, R. (2016). An analysis of determinants of going concern audit opinion: Evidence from Spain stock Exchange, *Intangible Capital*, 12(1), 1-16. <http://dx.doi.org/10.3926/ic.683>
- Geiger, M.A. & Raghunandan, K. (2002). Going-concern opinions in the 'new' legal environment. *Accounting Horizons*, 16(1), 17-26. <https://doi.org/10.2308/acch.2002.16.1.17>
- Goodman, B., Braunstein, D.N., Reinstein, A. & Gregory, W.G. (1995). Explaining auditors going concern decisions: assessing managements capability. *Journal of Applied Business Research*, 11(3), 82-93. <https://doi.org/10.19030/jabr.v11i3.5863>
- Haron, H., Hartadi, B., Ansari, M. & Ismail, I. (2009). Factors influencing auditors' going concern opinion. *Asian Academy of Management Journal*, 14(1), 1-19. <http://web.usm.my/aamj/14-1-2009.html>
- Harris, C.K. & Harris, W.T. (1990, April). An expert decision support system for auditor 'going concern' evaluations. Poster session presented at the Symposium on Applied Computing, Arkansas. <https://ieeexplore.ieee.org/document/82158>

- Koh, H.C. & Killough, L.N. (1990). The use of multiple discriminant analysis in the assessment of the going-concern status of an audit client. *Journal of Business Finance & Accounting*, 17(2), 179-192. <https://doi.org/10.1111/j.1468-5957.1990.tb00556.x>
- Koh, H.C. & Tan, S.S. (1999). A neural network approach to the prediction of going concern status. *Accounting and Business Research*, 29(3), 211-216. <https://doi.org/10.1080/00014788.1999.9729581>
- Kuruppu, N., Laswad, F. & Oyelere, P.B. (2003). The efficacy of liquidation and bankruptcy prediction models for assessing going concern. *Managerial Auditing Journal*, 18(6-7), 577-590. <https://doi.org/10.1108/02686900310482713>
- Lenard, M.J., Alam, P., Booth, D. & Madey, G. (2001). Decision-making capabilities of a hybrid system applied to the auditor's going-concern assessment. *International Journal of Intelligent Systems in Accounting, Finance & Management*, 10(1), 1-24. <https://doi.org/10.1002/isaf.190>
- Levitan, A.S. & Knoblett, J.A. (1985). Indicators of exceptions to the going-concern assumption. *Auditing: A Journal of Practice & Theory*, 5(1), 26-39. <https://meridian.allenpress.com/ajpt>
- Louwers, T.J. (1998). The relation between going-concern opinions and the auditor's loss function. *Journal of Accounting Research*, 36(1), 143-156. <https://doi.org/10.2307/2491325>
- Martens, D., Bruynseels, L., Baesens, B., Willekens, M. & Vanthienen, J. (2008). Predicting Going Concern Opinion with Data Mining. *Decision Support Systems*, 45, 765-777. <https://doi.org/10.1016/j.dss.2008.01.003>
- McKeown, J.C., Mutchler, J.F. & Hopwood, W. (1991). Towards an explanation of auditor failure to modify the audit opinions of bankrupt companies, *Auditing A Journal of Practice & Theory*, 10, 1-13. <https://meridian.allenpress.com/ajpt>
- Menon, K. & Schwartz, K.B. (1986). An empirical investigation of audit qualification decisions in the presence of going concern uncertainties, *Contemporary Accounting Research*, 3(2), 302-315. <https://doi.org/10.1111/j.1911-3846.1987.tb00640.x>
- Moradi, M., Salehi, M., Yazdi, H.S. & Gorgani, M.E. (2012). Going concern prediction of Iranian companies by using fuzzy c-means. *Open Journal of Accounting*, 1, 38-46. <https://doi.org/10.4236/ojacct.2012.12005>
- Mutchler, J.F. (1984). Auditors' perceptions of the going-concern option decision. *Auditing: A Journal of Practice and Theory*, 3(2), 17-30. <https://meridian.allenpress.com/ajpt>
- Mutchler, J.F. (1985). A multivariate analysis of the auditor's going-concern opinion decision. *Journal of Accounting Research*, 23(2), 668-682. <https://doi.org/10.2307/2490832>

- O'Leary, D.E. & Watkins, P.R. (1989). Review of expert systems in auditing, *Expert Systems Review for Business and Accounting*, 2(1), 3-22. <https://www.marshall.usc.edu/sites/default/files/doleary/intellcont/Review-of-expert-systems-in-auditing-1.pdf>
- Raghunandan, K. & Rama, D.V. (1995). Audit reports for companies in financial distress: before and after SAS no. 59. *Auditing: A Journal of Practice & Theory*, 14(1), 50-63. <https://meridian.allenpress.com/ajpt>
- Ruiz-Barbadillo, E., Go'mez-Aguilar, N., de Fuentes-Barbera, C. & Antonia Garcí'a-Benau, M. (2004). Audit quality and the going-concern decision-making process: Spanish evidence, *European Accounting Review*, 13(4), 597-620. <https://doi.org/10.1080/0963818042000216820>
- Salehi, M. & Fard, F.Z. (2013). Data mining approach to prediction of going concern using classification and regression tree (CART). *Global Journal of Management and Business Research*, 13(3), 25-29. <https://globaljournals.org/item/1475-data-mining-approach-to-prediction-of-going-concern-using-classification-and-regression-tree-cart>