

İŐLETMELERDE FİNANSAL BAŐARISIZLIK ÖNGÖRÜSÜNDE MAKİNE ÖĞRENMESİNİN KULLANIMI: BİST UYGULAMASI ¹

THE USE OF MACHINE LEARNING IN PREDICTING FINANCIAL FAILURE IN BUSINESSES: ISTANBUL STOCK EXCHANGE APPLICATION

İsmail Fatih CEYHAN  **

*Arařtırma Makalesi / Geliř Tarihi: 12.09.2023
Kabul Tarihi: 30.09.2023*

Öz

Çalıřmanın amacı Őletmelerin finansal başarısızlık riski ile ilgili tahmin yapay zekâ tekniklerinden makine öğrenmesi kullanılarak yapılmasıdır. Bu kapsamda, Borsa İstanbul Ulusal Pazar’da yer alan 14 firma ile Borsa İstanbul Yakın İzleme Pazarı’nda yer alan 14 firmanın 2022 yılı 12 aylık gelir tabloları ve bilançolarından elde edilen 43 adet finansal oran kullanılmıř makine öğrenmesi yöntemlerinden NaiveBayes, J48, RandomForest, LinearRegression, RandomTree kullanılmıřtır. Őirketlerin mali tabloları kullanılarak elde edilen veriler ile, makine öğrenmesi uygulama modellerinden hangisinin daha iyi sınıflandırma doęruluęu saęladığı arařtırılmıřtır. Ayrıca 2022 yılında yakın izleme pazarında yer alan bir Őirketin bir sonraki sene için finansal durumunun makine öğrenmesi ile öngörüsünün mümkün olup olmadığı test edilmiřtir. En yüksek sınıflandırma doęruluęu oranına RandomForest algoritması ve 10 kat çapraz doęrulama teknięinin birlikte uygulanması ile ulařıldığı, tek yıl için yapılan öngörü modelinde ise NaiveBayes algoritması ve 10 kat çapraz doęrulama teknięinin çok yüksek bir oranda başarı saęladığı sonuçlarına ulařılmıřtır.

Anahtar Kelimeler: Sınıflandırma, Finansal Sıkıntı, Finansal Başarısızlık, Makine Öğrenmesi, Tahmin.

JEL Sınıflaması: C38, G10, G33, L25

Abstract

The aim of the study is to estimate the risk of financial failure of enterprises by using machine learning, one of the artificial intelligence techniques. In this context, machine learning methods NaiveBayes, J48, RandomForest, LinearRegression, RandomTree were used with 43 financial ratios obtained from the financial statements of 14 companies in Borsa Istanbul Main Market and 14 companies in Borsa Istanbul Watchlist Market for the year 2022. With the data obtained using the financial statements of the companies, it is investigated which of the machine learning application models provides better classification accuracy. In addition, it was tested whether it is possible to predict the financial situation of a company in the close monitoring market in 2022 for the following year with machine learning. It was concluded that the highest classification accuracy rate was achieved by applying the RandomForest algorithm and 10-fold cross-validation technique together, while the NaiveBayes algorithm and 10-fold cross-validation technique achieved a very high rate of success in the prediction model for a single year.

Keywords: Classification, Financial Distress, Financial Failure, Machine Learning, Prediction.

JEL Classification: C38, G10, G33, L25.

¹ **Bibliyografik Bilgi (APA):** FESA Dergisi, 2023; 8(3) , 564 -580 / DOI: 10.29106/fesa.1359358

* Dr. Öğr. Üyesi, Bartın Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, ismailc@bartin.edu.tr, Bartın – Türkiye, ORCID: 0000-0002-4314-7374

1. Giriř

Ekonomik sistemin merkezine yerleřen menkul kıymet piyasalarının önemi son zamanlarda meydana gelen makro ve mikro ekonomik krizlerle birlikte daha çok kavranmaya başlamıřtır. Bu krizlerin temelinde yer alan finansal başarısızlık ve altında yatan unsurların tespitinin öneminin artmasına neden olmuřtur. Borsaya kote řirketlerin karlılıęındaki bozulma sadece iřletmenin ve personelin çıkarlarını tehdit etmekle kalmaz, aynı zamanda yatırımcıları da önemli mali kayıplarla karşı karşıya bırakır. Makro düzeyde de ekonominin etkilenmesi kaçınılmazdır. Daha iyi bir kurumsal yönetim için finansal başarısızlıęın öngörülmesine yönelik etkili bir erken uyarı sisteminin kurulması çabaları son zamanlarda artmaktadır.

Finansal başarısızlıęın öngörülmesinde finansal başarısızlık tahmin modelleri kullanılır. Kurumlar finansal başarısızlık tahmin modellerine dayanarak mevcut durumlarını teřhis edebilir ve stratejilerini oluşturabilirler. Yöneticiler, finansal başarısızlık riskini etkileyen temel göstergeleri yöneterek iřletmelerini daha istikrarlı bir řekilde yürütebilirler. Yatırımcılar da kurumların başarısızlık ihtimalini arařtırarak stratejilerini geliřtirebilir ve portföylerini revize edebilirler. Bunun yanında hükümetler de bu modelleri kullanarak makro planda politikalarını iyileřtirebilir ve ilgili mali düzenlemeleri gerçekleřtirerek finansal sistemin tasarlanmasını ve iyileřtirilmesini saęlayabilirler. Bunun için kullanılan makine öęrenimi algoritmaları ve istatistiksel modeller finans mühendislięinin en ileri noktasında yer almaktadır.

Bu kapsamda çalışmada, finansal başarısızlık öngörüsü ile ilgili çeřitli makine öęrenimi algoritmaları sınıflandırma metodolojileri kullanılmaktadır. Çalışmanın amacı iřletmelerin hem finansal açıdan mevcut durumunun belirlenmesi hem de gelecekteki finansal başarısızlık öngörüsü için makine öęrenmesi tekniklerinin kullanılmasının sonuçlarının arařtırılmasıdır.

Çalışmanın bundan sonraki planı řu řekildedir: Öncelikle kavramsal çerçeve sunulacak ardından literatürde finansal başarısızlık tahmini ile ilgili yapılan çalışmalar özetlenecek ve uygulamanın gerçekleřtirilmesinden sonra elde edilen bulgular temelinde makalenin sonuçları deęerlendirilecektir.

2. Kavramsal Çerçeve

Altmıř yılı aşkın bir geçmişe sahip olan finansal başarısızlık tahmin modelleri, firmaların finansal problemlerini belirleme ve gelecekte iflas edip etmeyeceğini tahmin etme amacını taşımaktadır. Bir firmanın finansal başarısızlıęının ekonomik sonuçları son derece kritik olup büyük önem taşımaktadır. Bu bağlamda, finansal sıkıntının tahminine yönelik modeller; girişimciler, yatırımcılar, kreditorler, denetçiler ve dięer tüm paydařların yoğun ilgisini çekmektedir. Bu modeller, sadece firmaların olası sıkıntı durumlarına iliřkin tahminlerle sınırlı kalmamaktadır. Ayrıca böyle bir durumun önlenmesi için nasıl bir davranıř sergilenmesi gerektięi konusu da büyük bir öneme sahiptir (Kulalı, 2014, s.156).

Ayrıca son asırda yařanan küresel finansal krizler ve kredi riskindeki artışlar yapılan finansal başarısızlık öngörülerinin önemini ortaya koymaktadır. Bu kapsamda Beaver'ın çalışmalarından itibaren konu kapsamlı bir řekilde arařtırılmaktadır (Beaver, 1966).

Yapılan çeřitli yapısal model çalışmalarından Merton (1974), Black-Scholes tipi bir fiyatlandırma modeli kullanarak kurumsal finansal başarısızlık riskini “temerrüde uzaklık” ölçüsü řeklinde ortaya koymuřtur. Hillegeist vd. (2004), Black–Scholes–Merton modeline dayanan piyasa bazlı bir ölçümün Altman'ın (1966) Z-skorundan ve Ohlson'un (1980) O-skorundan daha iyi performans gösterdięini ileri sürmektedir. Jessen ve Lando (2015) temerrüde uzaklık ölçüsünün finansal başarısızlık riskini tespit edebildięini desteklemektedir. Ayrıca Glover (2016) varlıkların oynaklıęını kullanarak yaptıęı bir deęiřiklikle temerrüde olan uzaklıęı ölçen çalışmasında, bir řirketin temerrüt maliyetlerinin hesaplanmasında yapısal bir model önermektedir. Brogaard vd. (2017) hisse senedi likiditesinin artmasının finansal başarısızlık riskini azalttıęını göstermek için çalışmasında temerrüde uzaklık yaklařımını kullanmıřtır.

Ancak son zamanlarda elde edilen sonuçlara göre finansal başarısızlık tahmininde istatistiksel yaklařımlara ve makine öęrenimi algoritmalarına sahip modellerin yapısal modellere göre daha başarılı sonuçlar saęladığı ortaya konmuřtur.

Makine öęrenimi kavramı Samuel (1959) tarafından önerilmiř ve bilgisayarlara açık bir program olmadan öęrenme yeteneęi veren bir disiplin olarak tanımlanmıřtır. Bu kavramı geliřtiren Mitchell (1997)'e göre bir bilgisayar programının performansını ölçen “P” metrięi, belirli “T” görev sınıflarına yönelik olarak “E” deneyimi ile geliřtiriliyorsa, bu durumda programın “E” deneyiminden öęrendięi söylenebilir ve “P” metrięi ile ölçölür. Bu bağlamda, finansal başarısızlık tahmini için bir makine öęrenmesi algoritmasının kullanılması, “P” gerçeک finansal verilerini “E” deneyimi ile “T” finansal başarısızlık riskini tahmin etme görevinde başarısızlık göstergesini

iyileřtiren bir dizi süreç olarak tanımlanabilir. Makine öğrenmesi tekniklerini kullanarak finansal başarısızlık öngörüsünde bulunma amacına yönelik yapılan arařtırmalardan Barboza vd. (2017) çalışmasında, makine öğrenmesi modellerinin finansal başarısızlık tahmininde daha iyi performans sergilediğini göstermektedir.

Makine öğrenimini kullanan bir finansal başarısızlık tahmini çoğunlukla, bir şirketin durumunu (= 0) normal ve (= 1) başarısız olarak tanımlanan iki veya daha fazla durumdan birinde olarak kategorize eden bir sınıflandırma problemini benimseyerek şirketin belirli bir durumda olmasının olasılığını hesaplamaktadır.

3. Literatür

Finansal başarısızlığı tahmin modelinin doğruluğunu artırmak için, Tayvan Menkul Kıymetler Borsası'nda alım satımı durdurulan ve askıya alınan şirketler kapsama alınmış ve finansal ve finansal olmayan oranlar, faktör analizi, yapay sinir ağı ve veri madenciliği teknikleri kullanılmıştır. Borsaya kayıtlı 68 şirket ve 37 oran ile yapılan bu çalışma ile dört önemli sonuca ulaşılmıştır: (1) Ne kadar çok faktör analizi kullanılırsa, yapay sinir ağı ve veri madenciliği yaklaşımları o kadar az doğruluk sağlanmaktadır. (2) Finansal başarısızlığın gerçekleşmesinden önceki iki sezon için elde edilen %82,14'lük bir doğruluk yüzdesi ile başarısızlığın gerçekleşme zamanı yaklaştıkça finansal doğruluk oranının arttığı tespit edilmiştir. (3) Faktör analizi finansal krizdeki şirketleri normal şirketler olarak sınıflandırma hatasını artırmaktadır. (4) Finansal başarısızlık tahmin modellerinden yapay sinir ağı, veri madenciliği kümeleme yaklaşımından daha iyi tahmin doğruluğu elde etmektedir. Bu nedenle, çalışma yapay zekâ yaklaşımının bir şirketin potansiyel finansal sıkıntısını tahmin etmek için geleneksel istatistiklerden daha uygun bir metodoloji olabileceğini önermektedir (Chen ve Du, 2009).

Diğer bir çalışmada Albayrak ve Koltan Yılmaz (2009) çalışmalarında, İMKB'de kayıtlı 173 firmanın 2004-2006 yıllarına ait yıllık finansal verilerini kullanarak, karar ağaçları tekniği ile şirketleri sınıflandırmada kullanılacak en önemli değişkenlerin işletme sermayesinin net satışlara oranı, stok devir hızı ve ekonomik rantabilite oranı değişkenleri olduğunu ortaya çıkarmışlardır.

Finansal risk analizi alanında popüler kümeleme algoritması seçimi yapmak için çok kriterli karar verme tabanlı bir yaklaşım sunan Kou, Peng ve Guoxun (2014) çalışmalarında, 3 farklı gerçek zamanlı kredi ve iflas riski veri tabanı üzerinde 3 çok kriterli karar verme metodu, 6 kümeleme algoritması ve 6 küme geçişleme indisi kullanarak oluşturdukları yaklaşımı test ederek bu metodun etkili olduğunu tespit etmişlerdir.

Finansal başarısızlık olgusunu inceleyen Geng, Bose ve Chen (2015) 2001-2008 yılları arasında Şangay ve Shenzhen Borsaları tarafından "özel muamele" etiketi alan 107 Çin şirketi için 31 finansal göstergelerle ve üç farklı dönemde, makine öğrenmesi tekniklerini kullanarak finansal başarısızlık uyarı modelleri oluşturularak, kontrol grubu firmalarla karşılaştırmışlardır. Sonuçta sinir ağlarının performansının, karar ağaçları ve destek vektör makineleri gibi diğer sınıflandırıcıların yanı sıra çoğunluk oylaması kullanılarak birleştirilmiş çoklu sınıflandırıcılardan oluşan bir topluluktan daha doğru olduğu gözlenmiştir. Çalışmanın diğer bir katkısı, toplam varlıkların net kâr marjı, toplam varlıkların getirisi, hisse başına kazanç ve hisse başına nakit akışı gibi finansal göstergelerin karlılıktaki bozulmanın tahmininde önemli bir rol oynadığını keşfetmesidir.

Salehi, Mousavi Shiri ve Bolandraftar Pasikhani (2016), 2011-2014 arasındaki dönemde finansal başarısızlığın tahmini amacıyla İran'daki 117 sorunlu firmanın finansal sıkıntıdan önceki iki yıllık muhasebe bilgilerini ve destek vektör makineleri, yapay sinir ağları, k-en yakın komşu ve Naive Bayes sınıflandırıcı tekniklerini kullanarak arařtırmışlardır. Bu şirketler, İran Ticaret Kanunu'nun 141. Maddesine göre birikmiş zararları öz sermayelerinin yarısını aşan şirketlerdir. Modellerin performansları arasında bir karşılaştırma yapılarak, yapay sinir ağlarının diğer tekniklerden daha iyi performans gösterdiği sonucuna varılmıştır.

Khemakhem ve Boujelbene (2018), sadece finansal ve finansal olmayan değişkenleri değil, aynı zamanda sınıf dengesizliğini de dikkate alarak kredi riskini değerlendirmek için yeni bir yöntem sunmayı amaçladıkları çalışmalarında yapay sinir ağları ve karar ağaçları tasarlamışlardır. Sonuçta, karlılık oranları, geri ödeme kapasitesi, ödeme gücü, kredi raporu süresi, teminatlar, şirket büyüklüğü, kredi numarası, sahiplik yapısı ve kurumsal bankacılık ilişkisi süresinin temerrüdü tahmin etmede kilit faktörler olduğu, ayrıca her iki algoritmanın da sınıf dengesizliğine karşı oldukça hassas olduğu ortaya çıkmıştır.

Yakın tarihli bir çalışmada, Farooq ve Qamar (2019), sektör ayarlaması ve verilerin çoğaltılmasından sonra seçilen örneklem kullanılmış, mali tablo ve borsa göstergelerinden en ilgili özellikleri çıkarmak için özelliklerin modele eklenip çıkartıldığı bir wrapper alt küme makine öğrenmesi yaklaşımı uygulanmıştır. Tahmin modelini geliřtirmek amacıyla DTNB, LMT ve A2DE Bayes modellerinin birleşimi kullanılmış ve ardından tüm modellerin performansı 10 kat çapraz doğrulama yöntemi ile değerlendirilmiştir. Sonuçta, önerilen model finansal sıkıntıyı %84,06 doğrulukla tahmin etmiş, ayrıca %33,33'lük bir kesme değeri dikkate alındığında ise bu oran %89,57'ye yükselmiştir.

Shang, Lu ve Zhou (2021) yaptıkları arařtırmada, nesnelere interneti ile büyük veri madenciliğine dayalı çoklu finansal göstergeler seçilmiştir. Daha gerçekçi finansal risk göstergeleri seçmek için tüm finansal göstergeler

arasındaki kurallar, sık bulanık seenek kümesi, paralel kurallar ve paralel madencilik algoritması ile belirlenerek minimum bulanık güvenilirlięi saęlayan bulanık ilişkilendirme kuralları elde edilmiştir. Sonuç olarak, alıřmada önerilen yöntem doğrulanmıştır.

Arařtırma makalelerinin yanı sıra finansal başarısızlık tahmini konusunda yapılmıř alıřmaları inceleyen birçok derleme makale de literatürde yer almaktadır (Balcaen ve Ooghe 2006; Ravi Kumar ve Ravi 2007; Devi ve Radhika 2018; Alaka vd. 2018).

3. Metodoloji

Sınıflandırma ile ilgilenen denetimli makine öğrenimi algoritmalarından bazıları řunlardır: Doğrusal Sınıflandırıcılar, Lojistik Regresyon, Naive Bayes Sınıflandırıcı, Perceptron, Destek Vektör Makinesi; Karesel Sınıflandırıcılar, K-Means Kümeleme, Boosting, Karar Aęacı, Rastgele Orman, Sinir aęları, Bayesian Aęları vb. (Taiwo, 2010)

Makine öğrenmesinde sınıflandırıcı olarak alıřmanın uygulama aşamasında kullanılan algoritmaların özellikleri ilgili bilgiler ařaęıda verilmektedir.

- Lojistik regresyon, oluřturma amacıyla sınıf kullanan ve tek bir tahminciyle tek bir multinomial lojistik regresyon modeli kullanan bir sınıflandırma işlevidir. Lojistik regresyon genellikle sınırdan, belirli bir uzaklıkla sınıflamaktadır. Bu veri seti daha büyük olduęunda uç noktalara (0 ve 1) doğru daha hızlı hareket eder. Lojistik regresyonu sınıflandırmada üstün yapan, olasılıklar hakkındaki bu ifadelerdir. Daha güçlü, daha ayrıntılı tahminler yapar ve farklı şekilde yenilenebilir ancak bu güçlü tahminler yanlış ıkma ihtimali de olabilir. Lojistik regresyon, Sıradan En Küçük Kareler (OLS) regresyonu gibi bir tahmin yaklaşımıdır. Bununla birlikte, lojistik regresyon ile tahmin, ikili bir sonuçla sonuçlanır (Newsom, 2015). Lojistik regresyon, uygulamalı istatistik ve kesikli veri analizi için en yaygın kullanılan araçlardan biridir. Lojistik regresyon doğrusal enterpolasyondur (Lojistik regresyon, 2023)
- Naive Bayesian Aęları, Bunlar, yalnızca bir ebeveyni (gözlemlenmemiş düęümü temsil eden) ve birkaç çocuęu (gözlemlenen düęümlere karşılık gelen) olan yönlendirilmiş grafiklerden oluřan ve ebeveynleri bağlamında çocuk düęümleri arasında güçlü bir bağımsızlık varsayımı olan çok basit Bayes aęlarıdır (Good, 1951). Bu nedenle, bağımsızlık modeli (Naive Bayes) tahmin etmeye dayanmaktadır (Nilsson, 1965). Bayes sınıflandırıcıları genellikle dięer daha sofistike öğrenme algoritmalarından daha az doğrudur, ancak Domingos ve Pazzani (1997) Naive Bayes sınıflandırıcısının standart kıyaslama veri kümelerinde karar aęacı, örnek tabanlı öğrenme ve kural için son teknoloji algoritmalarla geniş ölçekli bir karşılařtırmasını yapmış ve önemli özellik bağımlılıkları olan veri kümelerinde bile bazen dięer öğrenme řemalarından daha üstün olduęunu bulmuřtur.
- Destek Vektör Makineleri, yeni denetimli makine öğrenme tekniklerindedir (Vapnik, 1995). Destek Vektör Makinesi modelleri, klasik çok katmanlı algılayıcı sinir aęlarıyla yakından ilişkilidir ve iki veri sınıfını ayıran bir hiper düzlemin her iki tarafındaki marj kavramı etrafında döner. Marjı maksimize ederek ayırıcı hiper düzlem ile her iki tarafındaki örnekler arasında mümkün olan en büyük mesafeyi yaratmanın beklenen genelleme hatasında bir üst sınırı azalttıęı kanıtlanmıştır (Kotsiantis, 2007).
- Karar Aęaçları, örnekleri özellik deęerlerine göre sıralayarak sınıflandıran aęaçlardır. Bir karar aęacındaki her düęüm, sınıflandırılacak bir örnekteki bir özellięi temsil eder ve her dal düęümün alabileceęi bir deęeri temsil eder. Örnekler kök düęümden başlayarak sınıflandırılır ve özellik deęerlerine göre sıralanır (Kotsiantis, 2007). Veri madencilięi ve makine öğreniminde kullanılan karar aęacı öğrenimi, bir öęe hakkındaki gözlemleri öęenin hedef deęeri hakkındaki sonuçlarla eşleřtiren bir tahmin modeli olarak bir karar aęacı kullanır. Bu tür aęaç modelleri için daha açıklayıcı olanlar sınıflandırma aęaçları veya regresyon aęaçlarıdır [20]. Karar aęacı sınıflandırıcıları genellikle bir doğrulama kümesi kullanılarak budandıkları için karar aęaçlarının performansını deęerlendiren budama sonrası teknikleri kullanır. Herhangi bir düęüm kaldırılabilir ve kendisine sıralanan eğitim örneklerinin en yaygın sınıfına atanabilir (Kotsiantis, 2007).
- J48, aęaç oluřturmak için kullanılan bir sınıflandırıcı olup herhangi bir kod gerektirmez. Bir aęaç oluřtururken, J48 eksik nitelikleri reddeder, yani dięer kayıt için karakteristik niteliklere odaklanılarak bu şeylerin kalitesinin tahmin edilebileceęi düşünülür. J48 sınıflandırıcısı aęırlıklandırma yardımıyla yüksek doğruluęa sahiptir (Patil ve Barkade, 2018).

4. İşletmelerde Finansal Başarısızlık Riski Öngörüsünde Makine Öğrenmesi Uygulaması

4.1. Arařtırmanın Amacı, Kapsamı ve Kısıtları

Bu alıřmada işletmelerin finansal başarısızlık riski ile ilgili tahminin yapay zekâ tekniklerinden makine öğrenmesi kullanılarak yapılmasının sonuçları arařtırılmıştır. Bu kapsamda, Borsa İstanbul Ulusal Pazar’da yer alan 14 ve yakın izleme (gözaltı) pazarındaki 14 firmanın 2022 yılı 12 aylık gelir tabloları ve bilanoları

kullanılmıř makine öğrenmesi yöntemlerinden faydalanılmıřtır. Bu řirketlerin mali tabloları kullanılarak elde edilen veriler ile, makine öğrenmesi uygulama modellerinden hangisinin daha iyi sınıflandırma doęruluęu saęladığı arařtırılmıřtır. Ayrıca 2022 yılında yakın izleme pazarında yer alan bir řirketin sonraki sene için finansal durumunun makine öğrenmesi ile öngörüsünün mümkün olup olmadığı test edilmiřtir.

Yapılacak eğitim ve test faaliyetlerinden anlamlı sonuçlar çıkarabilmek için çalıřmadaki veri setinde kullanılacak sınıf eleman sayılarının eřit olması gerekir. Bu çalıřmada karřılařılan en önemli kısıtlar gözaltı pazarındaki firma sayısının 14 adet olması nedeniyle, ulusal pazardaki firmalardan da 14 adet seçilmesi, dolayısıyla kullanılan veri setinin toplam 28 firmayla sınırlı olmasıdır. Dięer kısıtlar da analizde kullanılan veri setinin yalnızca bir yıllık verilerden oluřmaması ve ayrıca tüm algoritmaların sınanmamasıdır.

4.2. Veri ve Yazılım

Amacımıza yönelik olarak öncelikle, 2022 yılında Yakın İzleme Pazarı'nda (gözaltı pazarı) ve Ulusal Pazar'da yer alan, banka vb. haricindeki řirketlerden unvan sırasına göre ilk 14 řirketin 2022 yılı yıllık finansal verileri (Kamu Aydınlatma Platformu, 2023) web sayfasındaki bilanço ve gelir tablolarından elde edilmiřtir. Modelin anlamlı olabilmesi için her iki grubun eřit sayıda olması gerekmektedir. Bu nedenle ulusal pazarda yer alan firma sayısı 14 ile sınırlanılmıřtır. Her iki grup firmanın listesi Tablo 1'de sunulmuřtur.

Tablo 1. Mali Tabloları Kullanılan Firmalar

	Ulusal Pazar'daki Firmalar		Yakın İzleme Pazarındaki Firmalar
1	Afyon Çimento Sanayi T.A.ř.	1	Atlantis Yatırım Holding A.ř.
2	Ahlatıcı Doęal Gaz Daęıtım Enerji ve Yatırım A.ř.	2	Birko Birleřik Koyunlulular Mensucat Ticaret ve Sanayi A.ř.
3	Akçansa Çimento Sanayi ve Ticaret A.ř.	3	Birlik Mensucat Ticaret ve Sanayi İřletmesi A.ř.
4	Aksa Akrilik Kimya Sanayii A.ř.	4	Casa Emtia Petrol Kimyevi ve Türevleri Sanayi Ticaret A.ř.
5	Alcatel Lucent Teletaş Telekomünikasyon A.ř.	5	Cosmos Yatırım Holding A.ř.*
6	Altınyāğ Madencilik ve Enerji Yatırımları Sanayi ve Ticaret A.ř.	6	Diriteks Diriliř Tekstil Sanayi ve Ticaret A.ř.
7	Anadolu Isuzu Otomotiv Sanayi ve Ticaret A.ř.	7	Ekiz Kimya Sanayi ve Ticaret A.ř.
8	Arçelik A.ř.	8	Eminiř Ambalaj Sanayi ve Ticaret A.ř.
9	Arena Bilgisayar Sanayi ve Ticaret A.ř.	9	Kervansaray Yatırım Holding A.ř.
10	Aselsan Elektronik Sanayi ve Ticaret A.ř.	10	Kuvva Gıda Ticaret ve Sanayi Yatırımları A.ř.
11	Aydem Yenilenebilir Enerji A.ř.	11	Mmc Sanayi ve Ticari Yatırımlar A.ř.
12	Ayen Enerji A.ř.	12	Otto Holding A.ř.
13	Aygaz A.ř.	13	Senkron Siber Güvenlik Yazılım ve Biliřim Çözümleri A.ř.
14	Aztek Teknoloji Ürünleri Ticaret A.ř.	14	Zedur Enerji Elektrik Üretim A.ř.*

Kaynak: (BİST řirketleri, 2023),

*(2023'te Yakın İzleme Pazarından Ana Pazara Geçen řirket)

Çalıřmada analiz ve deney yazılımı olarak açık eriřimli Weka programı kullanılmıřtır. Weka, Yeni Zellanda'daki Waikato Üniversitesi tarafından Waikato Environment for Knowledge Analysis adı ile geliřtirilmiř yazılımdır. Sistem java programlama dili ile yazılmıř ve GNU lisansı ile daęıtılmaktadır. Weka yazılımı birçok iřletim sistemi altında çalıřabilir. Platformdan baęımsızdır. Tek bir ara yüzde çok sayıda öğrenme algoritmasını saęlamaktadır (Waikato, 2023).

4.3. Uygulama

2022 yılında BİST Yakın İzleme Pazarı'nda 14 adet firma yer almaktadır. Bu 14 firma ile Ulusal Pazar'daki 14 firma arařtırmaya dahil edilmiřtir. Arařtırma kapsamına alınan toplam 28 firmanın bilanço ve gelir tablosu verilerinden yararlanarak anlamlı öznitelikler oluřtırmada kullanılan finansal oranlar Tablo 2'de açıklanmaktadır.

Tablo 2. Öznitelik Çıkarımında Kullanılan Finansal Oranlar

1	Cari Oran	Dönen Varlıklar / Kısa Vadeli Yabancı Kaynak
2	Dönen Varlıklar / Aktif	
3	Likit Oran	(Dönen Varlıklar - Stoklar) / Kısa Vadeli Yabancı Kaynak
4	Nakit Oran	Hazır Deęerler / Kısa Vadeli Yabancı Kaynak

5	Aktif Karlılık	Net Kâr / Varlıklar
6	Brüt Esas Faaliyet Kar Marjı	Brüt Esas Faaliyet Karı / Hasılat
7	Esas Faaliyet Kar Marjı	Esas Faaliyet Karı / Hasılat
8	FAVÖK Marjı	Faiz Vergi Öncesi Kar / Hasılat
9	Net Kar Marjı	Net Kar / Hasılat
10	Özsermaye Karlılığı	Net Kar / Özsermaye
11	VAFÖK Marjı	Vergi Amortisman Faiz Öncesi Kar / Hasılat
12	Finansman Gideri / Net Satıř	
13	Firma Deęeri / Defter Deęeri	
14	Firma Deęeri / FAVÖK	
15	Firma Deęeri / Net Satıř	
16	FK (Fiyat Kazanç)	Hisse Senedi Fiyatı / Hisse Senedi Bařına Kâr
17	Piyasa Deęeri / FAVÖK	
18	Piyasa Deęeri / Aktifler	
19	Piyasa Deęeri / Defter Deęeri	Hisse Senedi Piyasa Deęeri / Hisse Senedi Defter Deęeri
20	PD / Net Satıř	Hisse Senedi Piyasa Deęeri / Net Satıř
21	Aktif Büyüme	2. Yıl Toplam Varlıklar / 1. Yıl Toplam Varlıklar
22	Net Satıřlar Büyüme	2. Yıl Net Satıřlar / 1. Yıl Net Satıřlar
23	Özsermaye Büyümesi	2. Yıl Toplam Özsermaye / 1. Yıl Toplam Özsermaye
24	ROIC	Sürdürölen Faaliyetler Vergi Sonrası Kârı / (Dönen Varlıklar - Kısa Vadeli Yabancı Kaynak -Nakit ve Benzeri + Maddi Duran Varlıklar)
25	Borç Kaynak Oranı	Toplam Borçlar / Toplam Kaynaklar
26	Net Satıřlar / Kısa Vadeli Borçlar	
27	Stoklar / Dönen Varlıklar	
28	Net Borç / Aktifler	
29	FAVÖK / Kısa Vadeli Borçlar	
30	FAVÖK / Mali Borçlar	
31	Kısa Vadeli Borç / Aktif	
32	Net Satıřlar / Kısa Vadeli Borç	
33	Özsermaye / Aktifler	
34	Toplam Borç / Özsermaye	
35	Aktif Devir Hızı	Net Satıřlar / Ortalama Varlıklar
36	Alacak Devir Hızı	Ortalama Ticari Alacak / Net Satıřlar
37	Alacak Tahsil Süresi	365 / Alacak Devir Hızı
38	Dönen Varlıklar Devir Hızı	Net Satıřlar / Ortalama Dönen Varlıklar
39	Duran Varlıklar Devir Hızı Sektörel	Net Satıřlar / Ortalama Duran Varlıklar
40	Nakit Döndürme Süresi	(Satıřların Maliyeti / Ortalama Stok) + (Ticari Alacaklar / Günlük Satıřlar) – (Ticari Borçlar / Günlük Satıřların Maliyeti)
41	Özsermaye Devir Hızı	Net Satıřlar / Ortalama Özsermaye
42	Stok Devir Hızı	Satılan Mal Maliyeti / Ortalama Stoklar
43	Ticari Borç Devir Hızı	(Satılan malın Maliyeti +DS Stok- DB Stok) / Ortalama Ticari Borçlar

Kaynak: (Çabuk ve Lazol, 2011)

Ancak hesaplamalarda kullanılan řirket verilerinden pay ya da paydada bir veya daha fazla verinin bulunmaması nedeniyle, bazı řirketlerin sütunlarındaki bazı öznitelikler hesaplanamamıřtır. Dolayısıyla mevcut veri setine veri temizleme iřlemi uygulanmıř ve eksik öznitelik deęerleri yerine o öznitelilięin ortalama deęeri kullanılarak sütunlarda eksik veri bulunmaması saęlanmıřtır. (İstatistik Sitesi, 2023).

řirketlerin yakın izleme pazarında iřlem görmesine ařaęıdaki kořullarda karar verilmektedir (Para Limanı, 2014):

- Hisse senetleri Borsa'da iřlem gören řirketler ve/veya hisse senetleri iřlemleri ile ilgili olarak olaęandıřı durumların ortaya çıkması,

- Hisse senetleri Borsa'da iřlem gören řirketler tarafından kamunun zamanında, tam ve sürekli olarak aydınlatılmasında ve mevcut düzenlemelere uyum konusuna gerekli özenin gösterilmemesi,
- Yatırımcıların haklarının korunması ve kamu yararı geređi hisse senetlerinin Borsa kotundan ve/veya iřlem gördüğü pazardan geçici ya da sürekli çıkarılması sonucunu doğurabilecek geliřmelerin oluşması durumunda řirket Yakın İzleme Pazarında iřlem görür.

Tablo 3'te sunulduđu üzere çalışmamızda kullandığımız Ulusal Pazar'da yer alan her bir řirketin öznitelikleri veri tabanına aktarılarak tüm řirketler için bir satır veri tabanında oluşturulmuřtur. Satırlardaki tüm sütunlar hesaplanmış bu oranlara sahiptir. Ayrıca bu sütunun keřiřtiđi her bir satır ayrı bir řirketin bu deđiřkene ait verisini göstermektedir. Tablo 4'te ise Gözaltı Pazarı'nda yer alan tüm řirketler için hesaplanan öznitelikler veri tabanına aktarılmıř ve yine her řirketin veri tabanında bir satırı oluşturulmuřtur. Böylece eksiksiz veri seti Weka programında kullanıma hazırlanmıřtır. Hazırlanan bu veri seti Weka programındaki pek çok teknikte birlikte 10-kat çapraz doğrulama (10 fold) eđitim ve test kümesi yöntemleri kullanılarak sınanmıřtır. Her bir algoritma için eđitim ve test kümeleri ayrı ayrı test edilmiř ve sınıflandırıcıların doğru sınıflandırma yüzdesi belirlenmiřtir. Ardından sınıflandırıcıların bu başarı oranları karşılaştırılmıřtır. Sonuç olarak, yapılan analizde hangi tekniđin daha yüksek doğrulukta sınıflandırma yaptıđı, dolayısıyla bu tekniklerden hangisinin daha iyi sonuç verebildiđi ortaya çıkarılmaktadır.

Tablo 3. Ulusal Pazar’da Yer Alan Firmaların Öznitelik Verileri

Oranlar	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	
Firmalar	1	1,7	55,2	1,4	65,0	25,8	26,5	25,2	27,8	20,2	38,9	28,5	3,2	4,1	8,9	2,5	12,9	9,4	2,7	4,3	2,6	58,6	220,8
	2	1,1	37,6	1,1	63,7	3,0	6,5	5,4	6,8	2,6	7,2	13,0	10,9	1,7	19,1	1,3	60,2	22,9	1,1	2,6	1,1	389,3	227,2
	3	1,1	54,2	0,9	34,3	26,3	16,8	13,6	15,1	17,1	58,4	14,6	3,8	3,3	9,1	1,4	7,8	8,9	1,5	3,2	1,3	130,1	209,9
	4	1,4	54,1	0,8	39,6	32,8	24,6	21,3	22,6	19,6	79,8	21,6	6,9	5,3	7,7	1,8	8,7	7,6	2,6	5,2	1,7	20,9	109,1
	5	2,6	93,5	2,1	73,2	12,7	24,4	20,2	21,4	10,3	22,5	18,2	0,0	2,6	7,1	1,5	17,1	8,3	1,8	3,1	1,8	63,6	74,3
	6	1,9	8,6	1,9	103,2	3,5	63,1	58,8	79,1	26,7	7,6	91,3	49,7	1,8	10,0	7,9	18,3	6,2	0,5	1,1	4,9	57,1	206,9
	7	1,2	59,2	0,8	40,7	10,3	22,7	14,4	15,7	9,9	25,8	12,8	10,3	5,8	20,0	3,2	31,5	19,7	2,3	5,7	3,1	131,1	134,1
	8	1,2	69,6	0,8	30,9	4,0	29,5	6,4	8,9	3,2	19,5	10,3	10,0	4,1	8,7	0,8	17,5	6,4	0,6	3,0	0,6	55,4	96,4
	9	1,2	95,9	0,9	23,2	2,0	5,6	3,3	3,6	0,6	12,2	4,1	2,9	2,5	4,0	0,1	19,4	3,5	0,3	2,2	0,1	77,8	184,3
	10	1,3	50,4	0,8	19,2	19,5	33,4	25,2	26,9	33,8	36,6	36,0	8,3	3,7	15,5	4,2	11,9	15,0	1,9	3,6	4,0	63,8	75,2
	11	1,9	8,6	1,9	103,2	3,5	63,1	58,8	79,1	26,7	7,6	91,3	49,7	1,8	10,0	7,9	18,3	6,2	0,5	1,1	4,9	57,1	206,9
	12	1,5	33,5	1,5	90,6	21,0	37,9	36,9	39,6	23,5	56,9	38,9	12,4	3,2	4,8	1,9	6,9	4,1	1,1	2,7	1,6	72,6	331,3
	13	1,3	44,0	0,9	24,6	37,9	5,9	0,8	1,4	12,6	90,13	13,7	2,2	2,9	42,3	0,6	4,4	39,1	1,3	2,7	0,6	99,8	136,0
	14	2,4	92,1	1,5	38,2	29,9	17,7	14,7	15,0	10,9	60,3	15,8	2,3	4,2	7,8	1,2	10,5	7,6	2,2	4,1	1,1	134,3	136,0

Tablo 4. Ulusal Pazar'da Yer Alan Firmaların Öznitelik Verileri (Devam)

Oranlar	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	
Firmalar	1	42,5	41,1	36,4	420,3	17,4	-13,5	116,7	391,7	33,3	420,3	63,6	57,2	1,3	6,4	56,8	3,0	5,4	32,0	1,9	6,8	4,7
	2	29,2	17,0	42,2	295,5	1,1	-18,2	20,1	124,2	33,5	295,5	51,8	81,5	1,2	8,3	43,8	3,0	273,6	-11,1	2,8	230,3	6,5
	3	137,7	31,7	54,5	309,4	22,0	4,8	46,6	105,8	49,1	309,4	45,5	119,8	1,5	6,4	57,2	2,9	5,4	23,7	3,4	8,2	4,7
	4	102,5	62,3	49,7	340,5	35,7	6,2	76,9	165,0	38,1	340,5	50,3	98,9	1,7	8,4	43,5	2,9	2,9	19,9	4,1	6,4	4,5
	5	64,8	60,2	43,2	384,2	18,0	-25,7	82,2	1791,5	36,2	384,2	56,8	76,0	1,2	2,9	127,5	1,3	20,8	137,2	2,2	4,6	5,2
	6	74,2	7,6	51,7	307,7	0,3	32,7	243,3	28,0	4,5	307,7	48,3	107,2	0,1	3,3	109,4	1,6	49,8	41,3	0,3	152,5	5,2
	7	143,5	25,8	59,3	215,8	30,2	3,5	33,9	91,3	50,9	215,8	40,7	145,8	1,1	5,8	62,5	1,8	21,6	32,0	2,6	4,0	3,0
	8	28,7	15,6	79,5	223,5	31,8	20,4	19,8	36,3	60,0	223,5	18,9	421,4	1,2	4,1	89,3	1,8	9,3	100,6	6,0	3,4	3,7
	9	20,8	32,5	86,1	390,4	21,6	4,3	13,9	45,2	83,5	390,4	14,0	616,9	3,1	5,5	66,0	3,3	399,5	35,4	19,2	11,3	5,8
	10	55,1	19,4	47,6	152,1	32,9	6,8	40,8	211,4	39,0	152,1	52,1	91,3	0,6	2,9	125,3	1,2	20,8	168,7	1,1	2,2	3,0
	11	74,2	7,6	51,7	307,7	0,3	32,7	243,3	28,0	4,5	307,7	48,3	107,2	0,1	3,3	109,4	1,6	49,8	41,3	0,3	152,5	5,2
	12	144,6	37,0	55,2	401,1	0,0	19,7	158,7	86,0	22,9	401,1	41,9	131,5	0,9	15,4	23,7	3,4	49,8	1,4	2,4	0,0	16,4
	13	186,5	3,6	52,8	656,0	31,4	10,4	9,4	31,2	45,5	656,0	46,4	113,8	3,0	18,6	19,6	6,2	14,0	9,1	7,2	17,2	11,5
	14	226,8	51,9	45,9	570,6	27,5	6,1	85,7	179,1	44,1	570,6	54,1	84,8	2,7	4,5	80,7	3,0	399,5	94,5	5,5	7,4	10,3

Tablo 4. Yakın İzleme Pazarı'nda Yer Alan Firmaların Öznitelik Verileri

Oranlar	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22		
Firmalar	1	1,5	81	0,9	0,2	30	36,8	33,7	0,4	20,6	108,2	0,4	0,0	0,0	53,7	18,2	88,5	52,8	22,5	62,2	18,2	44,8	26,2	
	2	0,9	9,9	0,5	0,0	47	23,8	7,9	159,2	213,9	63,5	149,8	7,3	1,9	6,6	10,5	4,7	6,3	1,5	1,8	10,0	157,8	3,9	
	3	0,6	53,8	0,5	0,33	-	57,48	-	-	-	-	-	58,2	-	0,0	54,3	0,0	0,0	9,5	0,0	55,6	78,1	-	
	4	1,6	73,6	16,7	0,1	14,5	10,7	8,6	10,5	5,9	20,1	11,6	0,0	2,8	9,9	1,0	17,7	9,9	2,1	2,8	1,0	62,3	15,7	
	5	1,7	88,8	1,2	67,4	26,3	14,2	5,9	0,1	18,9	67,4	0,1	1,0	0,0	86,1	9,2	49,9	11,5	12,2	32,7	1,1	16,9	18,3,4	
	6	0,5	14,4	0,4	0,3	15,9	20,1	11,5	23,6	8,8	33,5	12,6	7,5	1,6	2,6	0,6	5,7	2,1	0,9	1,3	0,5	-	4,5	48,3,4
	7	0,3	6,1	0,3	0,3	34,6	1,9	-0,9	-0,8	30,5	72,8	40,9	11,5	2,9	0,0	1,8	4,8	-	1,184	2,4	1,3	1,5	57,7	95,4
	8	2,4	67,8	1,6	8,8	8,6	18	8,1	11,5	5,1	45,9	9,4	0,5	14,6	16,6	1,9	37,2	16,6	3,1	14,6	1,9	4,9	87,2	-
	9	0,0	0,8	0,0	0,1	7,9	4,8	-221,455	2544,67	2517,640	0,0	1365,2051	108,782	-	167,30,6	426,400	3,7	36,8	0,2	-	9354,4,9	50,9	-	10
	10	0,5	22,4	0,4	9,3	1,8	55,8	20,6	24,9	4,4	5,4	28,1	25,0	44,1	197,7	49,2	107,4,6	191,4,7	11,6	42,6	47,6	360,6	66,6,3	
	11	0,4	79	0,4	0,6	-	27,3	-29,8	-28,5	-33,0	-	-2,0	0,0	-	0,0	54,8	0,0	221,9	35,3	0,0	54,8	-	47,2	0,0
	12	6,6	24,2	6,1	12,4	54,1	75,5	60,8	1,0	225,2	99,3	1,0	1,8	10,9	38,5	24,8	11,0	25,3	3,8	7,2	24,8	278,6	99,9,6	
	13	2,8	92,3	2,3	0,6	6,8	23,1	15,9	16,4	23,9	12,7	32,4	3,2	3,8	46,3	7,6	31,2	45,4	2,1	3,7	7,4	-	-	78,5
	14	0,5	3,4	0,5	15,8	5,0	39,6	30,1	54,6	47,8	7,8	73,9	54,3	3,2	44,9	24,6	46,3	40,5	1,9	2,8	22,2	61,7	38,7,5	

Tablo 4. Yakın İzleme Pazarı'nda Yer Alan Firmaların Öznitelik Verileri (Devam)

Oranlar	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43
1	236,5	6,4	55,3	4,1	0,4	0,3	2,4	1766,3	55,1	6,9	36,2	1,2	1,5	2,2	164,4	1,9	194,2	64,9	1,7	4,5	1,5
2	325,8	1,7	16,8	116,4	43,4	6,5	185,2	541,3	11,7	116,4	83,2	20,2	0,2	2,9	125,1	1,3	5,0	194,2	0,3	1,8	2,8
3	-0,2	-0,6	128,1	14,2	20,5	-23,0	-21,7	-958,3	91,3	14,2	-28,1	-455,7	0,2	1,2	297,4	0,5	5,0	295,3	-0,6	1,2	1,2
4	71,0	23,7	26,5	6670,8	0,0	0,0	699,9	0,0	4,4	6670,8	73,5	36,1	2,5	10,0	36,4	3,6	21,2	65,9	3,4	12,3	4859
5	5,5	0,2	54,4	611	0,0	0,3	2,9	66,2	53,1	29,3	37,2	1,2	1,4	14,3	25,5	2,0	183,4	74,1	2,8	2,4	137,0
6	148,2	25,5	30,6	393,3	7,6	18,5	92,9	253,8	30,6	393,3	69,4	44,1	1,8	3,8	95,1	5,3	5,0	38,3	3,8	39,9	5,5
7	208,3	-0,9	41,4	424,0	0,0	31,9	-3,4	-4,0	20,1	424,0	58,6	70,6	1,1	81,8	4,5	13,0	8,5	-7,8	2,4	0,0	29,8
8	40,1	57,5	78,6	600,8	33,6	0,1	69,1	588,8	27,8	600,8	21,4	366,7	1,7	7,4	49,4	2,7	6,0	75,6	9,0	6,0	10,6
9	1,7	-0,7	109,4	0,0	0,3	86,3	0,7	24,3	105,7	0,0	-3,6	-3014	385 800	0,0	360 024	3234,0	33,5	-1366 5128	36173	0,5	6,8
10	107,0	10,7	72,7	84,7	16,9	38,7	21,1	28,1	49,4	84,7	27,4	265,6	0,4	4,2	87,6	1,7	1516,0	97,1	1,2	3,7	4,1
11	0,0	0,0	195,9	31,3	0,0	-1,2	-8,9	0,0	195,9	31,3	-115,8	-169,2	0,4	0,9	399,7	0,8	33,5	375,2	0,7	0,0	14,9
12	215,0	1,3	47,7	4,1	0,0	0,0	4,0	10,1	3,7	4,1	52,3	0,9	0,2	3,4	109,0	1,2	2,1	-58,2	0,4	11,3	2,6
13	12,1	6,3	43,1	83,8	20,0	4,2	13,7	162,8	32,6	83,8	56,9	75,7	0,3	0,5	719,6	0,3	32,4	921,8	0,5	1,2	3,3
14	72,9	2,9	33,8	131,9	4,3	20,3	72,0	29,4	6,6	131,9	66,0	51,2	0,1	4,6	78,9	2,7	49,8	53,1	0,2	141,6	12,8

4.4. Bulgular

Tablo 5’te Weka programında ulařılan sonuçlarda yer alan ‘dođru pozitif’, ‘yanlıř pozitif’, ‘dođru negatif’ ve ‘yanlıř negatif’ deđerleri gsterilmektedir. alıřmada yer alan hata matrislerinde de grleceđi zere ‘a’ sınıfı ulusal pazar řirketlerini, ‘b’ sınıfı ise gzaltı pazarı řirketlerini temsil etmektedir. Sonu olarak ulusal pazarda sınıflandırılması gerekli bir řirket ulusal pazarda sınıflandırılmıřsa ‘Dođru Pozitif’, ama aynı řirket gzaltı pazarında sınıflandırılmıř ise ‘Yanlıř Pozitif’ sınıflandırılmıř olur. Diđer yandan gzaltı pazarında sınıflandırılması gereken bir řirket gzaltı pazarında sınıflandırılmıřsa ‘Dođru Negatif’, ama aynı řirket ulusal pazarda sınıflandırılmıřsa ‘Yanlıř Negatif’ olarak sınıflandırılmıřtır (Kırılıođlu ve Ceyhan, 2014, s.27).

Tablo 5. Hata Matrisi (Confusion Matrix)

		TAHMİN EDİLEN			
GEREKLEŐEN		Pozitif	Sınıflama	Negatif	Sınıflama
	Pozitif	Dođru Pozitif	a = a	Yanlıř Negatif	a = b
Negatif	Yanlıř Pozitif	b = a	Dođru Negatif	b = b	

alıřmada birok sınıflandırıcı ve test tekniđi kullanılmıř ve yksek dođruluk sađlayan teknikler ortaya ıkarılmıřtır. Veri seti, 10-kat apraz dođrulama tekniđi ile eđitilmıř ve yksek dođruluk sađlayan tekniklerin sonuları Tablo 6’da sunulmuřtur.

Tablo 6. Sınıflandırma Algoritmalarının Bařarı Durumu Karřılařtırması

Sınıflandırıcı	Naive Bayes	J48	Random Forest	Classification Via Regression	Random Tree
Test Modu	<i>10-Fold</i>	<i>10-Fold</i>	<i>10-Fold</i>	<i>10-Fold</i>	<i>10-Fold</i>
Dođru Pozitif	13	14	14	13	12
Dođru Negatif	9	9	12	11	11
Yanlıř Pozitif	5	5	2	3	3
Yanlıř Negatif	1	0	0	1	2
Dođru Sınıflandırılan rnek Sayısı	22	23	26	24	23
Yanlıř Sınıflandırılan rnek Sayısı	6	5	2	4	5
Dođru Sınıflandırma Oranı (%)	78,57	82,14	92,86	85,71	82,14
Yanlıř Sınıflandırma Oranı (%)	21,43	17,86	7,14	14,29	17,86
Kappa statistic	0,5714	0,6429	0,8571	0,7143	0,6429
Mean absolute error	0,2143	0,2121	0,2679	0,2694	0,1786
Root mean squared error	0,4629	0,4148	0,3093	0,3575	0,4226
Relative absolute error	%42,40	%41,96	%53,01	%53,87	%35,34
Root relative squared error	%91,56	%82,04	%61,18	%71,49	%83,58

Elde edilen bu sonulara gre;

NaiveBayes algoritması ve 10 kat apraz doęrulama teknięi uygulandıęında, veri setinde 13 adet “doęru pozitif” řeklinde sınıflandırılan, 9 adet “doęru negatif” řeklinde sınıflandırılan, 5 adet “yanlıř pozitif” řeklinde sınıflandırılan ve 1 adet “yanlıř negatif řeklinde” sınıflandırılan rnek bulunmuřtur. Toplamda 22 adet doęru sınıflandırılan ve 6 adet ise yanlıř sınıflandırılan rnek sayısına ulařılmıřtır. Sonu olarak modelin doęru sınıflandırma oranı %78,57 olarak hesaplanmıřtır.

Dięer algoritmaların sonuları ařaęıda verilmiřtir:

J48 algoritması ve 10 kat apraz doęrulama teknięi kullanıldıęında, toplam 23 adet doęru sınıflandırılan ve toplam 5 adet yanlıř sınıflandırılan rnek sayısı elde edilmiřtir. Sonu olarak modelin doęru sınıflandırma oranı %82,14 olarak bulunmuřtur.

RandomForest algoritması ve 10 kat apraz doęrulama teknięi kullanıldıęında, toplam 26 adet doęru sınıflandırılan ve toplam 2 adet yanlıř sınıflandırılan rnek sayısı elde edilmiřtir. Sonu olarak modelin doęru sınıflandırma oranı %92,86 olarak bulunmuřtur.

ClassificationViaRegression algoritması ve 10 kat apraz doęrulama teknięi kullanıldıęında toplam 24 adet doęru sınıflandırılan, toplam 4 adet ise yanlıř sınıflandırılan rnek sayısı elde edilmiřtir. Sonu olarak modelin doęru sınıflandırma oranı %85,71 olarak bulunmuřtur.

RandomTree algoritması ve 10 kat apraz doęrulama teknięi kullanıldıęında ise toplam 23 adet doęru sınıflandırılan, toplam 5 adet ise yanlıř sınıflandırılan rnek sayısı elde edilmiřtir. Sonu olarak modelin doęru sınıflandırma oranı %82,14 olarak bulunmuřtur.

Buna ilaveten 2023 yılında yakın izleme pazarından ana pazara ıkan bir firma iin, 2022 yılı verileri eęitim seti olarak kullanılmıř ve finansal durumunun tahmini iřlemi yapılmıřtır. Tablo 7’de grleceęi zere ilgili firmanın finansal oranları hesaplanarak znitelik verileri elde edilmiřtir.

Tablo 7. 2023 Yılında Ana Pazara ıkan Zedur Firmasının znitelik Verileri

Sıra	Deęer	Sıra	Deęer	Sıra	Deęer	Sıra	Deęer	Sıra	Deęer
1	0,66	2	4,57	3	0,57	4	8,66	5	4,77
6	30,54	7	18,6	8	47,77	9	16,45	10	8,08
11	57,16	12	43,51	13	4,08	14	62,08	15	30,63
16	56,17	17	55,26	18	2,16	19	3,63	20	27,26
21	62,21	22	-4,94	23	66,55	24	2,05	25	39,94
26	56,52	27	9,47	28	26,72	29	56,13	30	19,17
31	6,93	32	113,76	33	59,63	34	66,98	35	0,1
36	4,72	37	77,33	38	1,78	39	32,78	40	39,57
41	0,17	42	29,38	43	7,27				

Yapılan test iřleminin ardından ortaya ıkan sonular Tablo 8’de verilmiřtir.

Tablo 8. Zedur Firması İle İlgili Sınıflandırma Bařarısı

Sınıflandırıcı	NaiveBayes
Test Modu	<i>User supplied</i>
Doęru Pozitif	1
Doęru Negatif	0
Yanlıř Pozitif	0
Yanlıř Negatif	0
Doęru Sınıflandırılan rnek Sayısı	1
Yanlıř Sınıflandırılan rnek Sayısı	0
Doęru Sınıflandırma Oranı (%)	100
Yanlıř Sınıflandırma Oranı (%)	0

Kappa statistic	1
Mean absolute error	0
Root mean squared error	0
Relative absolute error	0
Root relative squared error	0

Elde edilen bu sonulara gre; NaiveBayes algoritması ve 10 kat apraz doęrulama teknięi uygulandıęında 2023 yılında yakın izleme pazarından ıkmıř olduęu %100' lk bir bařarı ile tespit edilmektedir.

5. Sonu ve Deęerlendirme

Yapay zek teknolojileri hızla yaygınlařmakta ve hayatın hemen hemen her alanında kendine yer bulmaktadır. Finans disiplini de ngr modelleri, bařta yatırımcılar olmak zere finans dnyasındaki tm aktrler iin olduęu nemlidir. Yapay zek finansal tahminlemeyi olduęu geliřmiř matematiksel modeller zerinden yapmaya olanak vermektedir. zellikle 2016 yılından itibaren arařtırmacıların bu alana ynelimlerinin arttıęını ve yapay zek teknolojilerinin finansa, portfy ynetimi, kredi risk ynetimi, algoritmik ticaret ve davranıřsal finans alanlarında sıklıkla kullanılmaktadır (Demirci, 2023).

Makine ęrenmesi ise son dnemde ortaya ıkmıř, ham veriden kullanılabilir bilgi ortaya ıkaran gzde konulardan biridir. Giderek global ky haline gelen dnyada her gn sayısız veri ortaya ıkmaktadır. Bu yzden makine ęrenmesi teknikleri ile iřlenmiř veriler elde etmek ve faydalanabileceęi bilgilere ulařmak her firmanın arzudur. Byk veri, nesnelerin interneti, bulut biliřim ve dięer fikir ve teknolojiler sosyal hayata entegre edildike, byk veri teknolojisi kurumların finansal verilerini iřlemelerini geliřtirebilir. Aynı zamanda, iřletmeler arasındaki rekabetin řiddetlenmesiyle birlikte, yatırımcılar ve iřletmeler finansal sıkıntı uyarılarının kurumsal ynetimdeki rolne daha fazla nem vermiřlerdir.

Buradan hareketle arařtırmada iřletmelerin finansal durumlarının tespitinde yapay zek tekniklerinden veri madencilięinin kullanımı zerine bir analiz yapılmıřtır.

Arařtırmanın uygulama ařamasında, 2022 yılında Borsa İstanbul'da yakın izleme pazarında bulunan 14 řirketin finansal tabloları ile ulusal pazarda yer alan 14 firmanın finansal tabloları kullanılmıřtır. Elde edilen ham verilerden ncelikle 43 adet finansal oran hesaplanmıř, ardından bunlar aık eriřim makine ęrenmesi programı olan Weka'da kullanılabilir znelik verilerine dnřtrlerek arff dosyası řekline getirilmiřtir. Bu veriler, Naive Bayes, J48, Random Forest, Classification Via Regression, Random Tree algoritmaları ile 10 kat apraz doęrulama teknięiyle test edilmiřtir. En yksek doęru sınıflandırma oranına yzde 92,86 bařarı oranıyla, Random Forest algoritması ve 10 kat apraz doęrulama teknięi ile ulařılmıřtır. Daha sonra sırasıyla, Yzde 85,71 ile regresyon, yzde 82,14 ile hem J48 hem de Random Tree ve yzde 78,57 ile Naive Bayes sınıflandırma bařarısı gstermiřtir.

Ayrıca, 2023 yılında yakın izleme pazarından ana pazara ıkan bir firmanın finansal durumunun tahmini iin yapılan testte, 2022 yılı verileri eęitim seti olarak kullanılarak gerekleřtirilmiř. Sonu olarak yzde yz oranında doęru tahmin bařarısı saęlanmıřtır.

Dolayısıyla herhangi bir řirketin finansal sıkıntı ierisine girip girmeyeceęi hakkında tahminde bulunulacaksa, yine bir řirketin yakın izleme pazarına alınıp alınmayacaęı ya da normal pazara dnp dnmeyeceęi sorgulanıyorsa veri madencilięinin kullanılması yerinde olacaktır.

alıřmamızda  nemli kısıt bulunmaktadır. Bunlardan birincisi, alıřmada kullanılan veri setinin sadece řirketlerin 2022 yılı 12 aylık mali tablolarından elde edilmesidir. İkincisi, alıřmada kısıtlı miktarda algoritma kullanılmıřtır. nc kısıt ise arařtırmanın yapıldıęı dnem itibarıyla gzaltı pazarında sadece 14 firma bulunduęu iin, ulusal pazarda da 14 firmanın mali tabloları kullanılmak zorunda kalınmıřtır.

Bu alıřma kısıtlarını elimine etmek amacıyla yapılacak arařtırmalarda, veri setini oluřtururken nesnelerin interneti ve sosyal medya aralarının kullanılmasıyla beraber ortaya ıkan byk veri kullanılabilir, ayrıca daha

uzun zaman aralıkları ve farklı pazarlar ele alınabilir, diđer algoritma ve teknikler de kullanarak alıřma genişletilebilir.

Kaynaka

AIX, (2023, 9, 2). <https://aix.web.tr/en/yapay-zeka-ve-veri-madenciligi/> adresinden alındı

ALAKA, H.A., OYEDELE, L.O., OWOLABI, H.A., KUMAR, V., AJAYI, S.O., AKINADE, O.O., & BİLAL, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Syst. Appl.*, 94, 164–184.

ALBAYRAK, A., & KOLTAN YILMAZ, ř. (2009). Veri Madenciliđi Karar Ađacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31-52.

ALPAYDIN, E. (2013). *Yapay Öğrenme: Introduction to Machine Learning*. İstanbul: Bođaziçi Üniversitesi Yayınevi.

ALTMAN, E.I. (1968). Financial Ratios, Discriminant analysis and the prediction of corporate bankruptcy. *J. Financ.* 23, 589–609.

BALCAEN, S., & OOGHE, H. (2006). 35 years of studies on business failure: An overview of the classic statistical methodologies and their related problems. *Br. Account. Rev.*, 38, 63–93.

BARBOZA, F., KİMURA, H., & ALTMAN, E. (2017). Machine learning models and bankruptcy prediction. *Expert Syst. Appl.*, 83, 405–417.

BEAVER, W.H. (1966). Financial ratios as predictors of failure. *J. Account. Res.* 4, 71–111.

BELL, J. (2015). *Machine Learning: Hands-On for Developers and Technical Professionals*. New Jersey: John Wiley & Sons.

BİST Şirketleri. (2023, 7, 2). Kamu Aydınlatma Platformu: <http://www.kap.gov.tr/sirketler/islem-goren-sirketler/pazarlar> adresinden alındı

BORAN, L. (2012). *Veri Madenciliđinin Türk İşletmelerin Finansal Tablolarına Uygulanması ve Uygulama Örneđi*. Yayımlanmamış Doktora Tezi, Marmara Üniversitesi S.B.E., İstanbul.

BROGAARD, J., LI, D., & XIA, Y. (2017). Stock Illiquidity and default risk. *J. Financ. Econ.*, 124, 486–502.

CHEN, W. S., & DU, Y. K. (2009). Using Neural Networks and Data Mining Techniques For The Financial Distress Prediction Model. *Expert systems with applications*, 36(2), 4075-4086.

CEYHAN, İ. F. (2014). *Bađımsız denetim kalitesini artırıcı bir yöntem olarak veri madenciliđi: Borsa İstanbul uygulaması*. Yayımlanmamış Doktora Tezi, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü, Sakarya.

ABUK, A., & LAZOL, İ. (2011). *Mali Tablolar Analizi (11. b.)*, Bursa: Ekin Yayınevi.

DEMİRCİ, F. (2023). Finasta Yapay Zekâ ve Makine Öğrenme Üzerine Bibliyometrik Bir Arařtırma. E. B. Ceyhan, & İ. F. Ceyhan içinde, *Yapay Zekâ Alan Uygulamaları-1* (s. 1-25). Ankara: Nobel.

DEVI, S.S., & RADHIKA, Y. A (2018). A survey on machine learning and statistical techniques in bankruptcy prediction. *Int. J. Mach. Learn. Comput.*, 8, 133–139.

DOMINGOS, P. & PAZZANI, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, 29, 103–130.

FAROOQ, U., & QAMAR, M. A. J. (2019). Predicting Multistage Financial Distress: Reflections on Sampling, Feature and Model Selection Criteria. *Journal of Forecasting*, 38(7), 632-648.

GOOD, I.J. (1951). Probability and the Weighing of Evidence, *Philosophy*, 26, 97, 163-164. <https://doi.org/10.1017/S0031819100026863>.

GENG, R., BOSE, I., & CHEN, X. (2015). Prediction of Financial Distress: An Empirical Study of Listed Chinese Companies Using Data Mining. *European Journal of Operational Research*, 241(1), 236-247.

GLOVER, B. (2016). The expected cost of default. *J. Financ. Econ.*, 119, 284–299.

- HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. H. (2001). *The elements of statistical learning, Data mining, inference, and prediction*, New York: Springer Verlag.
- HILLEGEIST, S.A., KEATING, E.K., CRAM, D.P., & LUNDSTEDT, K.G. (2004). Assessing the probability of bankruptcy. *Rev. Account. Stud.*, 9, 5–34.
- JESSEN, C., & LANDO, D. (2015). Robustness of distance-to-default. *J. Bank. Financ.*, 50, 493–505.
- İSTATİSTİK SİTESİ*. (2023, 5, 9). <http://www.stat.gen.tr/index.php?istek=sinif&dersid=ist01&konuid=ver01&max=1> adresinden alındı
- KHEMAKHEM, S., & BOUJELBENE, Y. (2018), Predicting Credit Risk on The Basis of Financial and Non-Financial Variables and Data Mining, *Review of Accounting and Finance*, 17 (3), 316-340.
- KOTSIANTIS, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. *Informatica*, 31, 249 – 268.
- KOU, G., PENG, Y., & GUOXUN, W. (2014). Evaluation of Clustering Algorithms for Financial Risk Analysis Using MCDM Methods. *Information Sciences*, 275, 1-12.
- KULALI, İ. (2014). Muhasebe Temelli Tahmin Modelleri Işığında, Finansal Sıkıntı ve İflasın Karşılaştırılması. *Sosyoekonomi Dergisi*, 22, 153-170.
- KUZEY, C., UYAR, A., & DELEN, D. (2014). The Impact of Multinationality on Firm Value: A Comparative Analysis of Machine Learning Techniques. *Decision Support Systems*, 59, 127–142.
- LOJİSTİK REGRESYON*, (2023, 8,10). 234 – 262.
<https://www.stat.cmu.edu/~cshalizi/ADAfaEPoV/ADAfaEPoV.pdf>,
- MCKEE, T. (1989). *Modern Analytical Auditing: Practical Guidance for Auditors and Accountants*. New York: Quorum Books.
- MERTON, R.C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *J. Financ.*, 29, 449–470.
- MITCHELL, T. (1997). *Machine Learning*, New York: McGraw Hill.
- NEWSOM, I. (2015). Data Analysis II: Logistic Regression. http://web.pdx.edu/~newsomj/da2/ho_logistic.pdf
- NILSSON, N.J. (1965). *Learning machines*. New York: McGraw-Hill. Published in: Journal of IEEE Transactions on Information Theory 12(3). doi: 10.1109/TIT.1966.1053912
- NISBET, R., ELDER, J., & MINER, G. (2009). *Handbook of Statistical Analysis and Data Mining Applications*, San Diego: Academic Press.
- OHLSON, J.A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *J. Account. Res.*, 18, 109–131.
- PATİL, R., & BARKADE, V. M. (2018). Class-Specific Features Using J48 Classifier for Text Classification, *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, Pune, India, 1-5, doi: 10.1109/ICCUBEA.2018.8697473.
- PARA LİMANI*. (2023, 3, 7). <http://www.paralimani.com/gozalti-pazari-ne-demek-haberi-38186/> adresinden alındı
- RAVI KUMAR, P., & RAVI, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques—A review. *Eur. J. Oper. Res.*, 180, 1–28.
- SAMUEL, A.L. (1959). Some studies in machine learning using the game of checkers. *IBM J. Res. Dev.*, 3, 210–229.
- SALEHI, M., MOUSAVI SHIRI, M., & BOLANDRAFTAR PASIKHANI, M. (2016). Predicting Corporate Financial Distress Using Data Mining Techniques: An Application in Tehran Stock Exchange, *International Journal of Law and Management*, 58 (2) 216-230.
- SHANG, H., LU, D., & ZHOU, Q. (2021). Early Warning of Enterprise Finance Risk of Big Data Mining in Internet of Things Based on Fuzzy Association Rules. *Neural Comput & Applic*, 33, 3901–3909.

TAIWO, O. A. (2010). *Types of Machine Learning Algorithms, New Advances in Machine Learning*, Yagang Zhang (Ed.), University of Portsmouth United Kingdom. 3 – 31.

VAPNIK, V. N. (1995). *The Nature of Statistical Learning Theory*. (2nd ed.). New York: Springer Verlag. 1–20.