

Şirket Değerlemede Makine Öğrenmesi Algoritmalarının Kullanımına Yönelik Bir Uygulama: Holding Şirketleri Örneği*

Araştırma Makalesi /Research Article

Onur ŞEYRANLIOĞLU¹
Alper KARAVARDAR²

ÖZ: Bu araştırmanın amacı, şirket değerini etkileyen unsurların tespit edilmesi, bu unsurlardan hareketle finansal oranlar/veriler kullanılarak Türkiye’de Borsa İstanbul Yatırım ve Holding Endeksi’nde (BİST XHOLD) işlem gören holding şirketlerinin şirket değerlerini tahmin etme aracı olarak makine öğrenimi algoritmalarından Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), Karar Ağaçları (KA) ve Rastgele Orman (RO) ile uygulanabilirliğini ortaya koymaktır. Belirtilen algoritmalar ile dört adet model kurulmuş ve bu modellerin tahmin gücü sınanmıştır. Bulgulara göre piyasa değerini R^2 , MAE ve RMSE ölçütleri baz alınarak YSA algoritmasının daha güçlü tahmin ürettiği görülmüştür. Bu araştırma ile şirket değerinin tahminine ve gelecek fiyatların öngörüsüne yönelik literatür incelenmiş, finansal oranlar/verileri içeren bütüncül bir yapı ortaya koyularak, yatırımcılara ve analistlere hisse senedi yatırımlarında ve şirket değerlendirme süreçlerinde makine öğrenimi algoritmaları ile geleneksel değerlendirme yaklaşımlarına kıyasla farklı bir bakış açısı sunulmuştur.

Anahtar Kelimeler: Şirket Değerlemesi, Yapay Sinir Ağları, Destek Vektör Makineleri
JEL Sınıflandırması: C8, G17, G11.

An Application for the Use of Machine Learning Algorithms in Company Valuation: The Case of Holding Companies

ABSTRACT: The purpose of this study is to determine the factors affecting company value and to demonstrate the applicability of machine learning algorithms Artificial Neural Networks (ANN), Support Vector Machines (SVM), Decision Trees (DT) and Random Forest (RF) as a means of predicting company values of holding companies traded in Borsa İstanbul Investment and Holding Index (BIST XHOLD) in Türkiye by using financial ratios/data based on these factors. Four models were constructed with these algorithms and the predictive power of these models was tested. According to the findings, it was observed that the ANN algorithm produced a stronger prediction of market value based on R^2 , MAE and RMSE. With this research, the literature on the estimation of company value and prediction of future prices has been analysed, a holistic structure including financial ratios/data has been presented, and a different perspective has been presented to investors and analysts in stock investments and company valuation processes compared to traditional valuation approaches with machine learning algorithms.

Keywords: Company Valuation, Artificial Neural Networks, Support Vector Machines
JEL Classification: C8, G17, G11.

Geliş Tarihi / Received: 13/02/2024

Kabul Tarihi / Accepted: 08/04/2024

*Bu araştırma Prof. Dr. Alper KARAVARDAR danışmanlığında Onur ŞEYRANLIOĞLU’nun “Şirket Değerlemede Makine Öğrenmesi Algoritmalarının Kullanımı: Holding Şirketleri Üzerine Bir Araştırma” adlı doktora tezinden üretilmiştir.

¹ Dr. Öğr. Üyesi, Giresun Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, onurseyanlioglu@gmail.com, orcid.org/0000-0002-1105-4034.

² Prof. Dr., Giresun Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, akaravardar@yahoo.com, orcid.org/0000-0001-7330-4038.

1. Giriş

Son yıllarda şirket birleşmeleri, satın almalar, halka açılmalar, özelleştirmelerin artması ve teknolojik gelişmelerin etkisi ile yatırımcıların sermaye piyasalarına erişimin kolaylaşması, bilgiyi ve veriyi azami verimlilikle kullanarak edinilen varlıkların değer tespiti finans alanında önemli odak noktalarından birisi haline gelmiştir. Varlıkların değerinin belirlenmesi geçmişten bugüne üzerinde tartışma yürütülen konuların başında gelirken, bir varlık ister finansal olsun ister reel bir değeri söz konusudur. Bu varlıklara başarılı bir şekilde yatırım yapmanın ve bu varlıkları yönetmenin anahtarı yalnızca değer ne olduğunu anlamak değil, aynı zamanda değeri yaratan kaynakları anlamaktan geçmektedir (Gürbüz ve Ergincan, 2008: 3). Damodaran (2006), değer bakanın gözünde olduğu ve bir varlık için bedeli ödemeye razı başka yatırımcılar varsa, bu fiyatın biçilen bedel ne olursa olsun meşru sayılacağını iddia edenlerin açık bir şekilde mantıksız akıl yürüttüklerini ifade etmiştir ve finansal varlıkların, yatırımcıları onlardan nakit akımı bekledikleri için satın almaları gerektiğini ileri sürmüştür. Burada devreye bir şeyin değerini belirlemek olan değerlendirme girmektedir. Değerleme, değerlemeyi yapan analistin amacını ve görüşünü içermesi, öznel bir şekilde oluşturulduğundan göreceli bir kavramdır (Hood ve Lee, 2011: 22). Değerlemeyi etkileyen birçok bileşen söz konusudur ve bu durum çok farklı görüşlere de yol açabilmektedir (Hitchner, 2006: 1). Farklı görüşlerin var olması, değer tam olarak saptanmasını güçleştirmektedir. Özellikle şirket değerinin belirlenmesinde en önemli unsur ise şirketin gerçek değerinin tespitidir. Gerçek değer, arz ve talebe göre piyasa tarafından biçilen değer değil, şirketin değer yaratan unsurlarını dikkate alarak hesaplanan değeridir (Ercan vd., 2006: 2).

Birbirleri ile ilişkili olan değer ile fiyat kavramları uygulamada benzer anlamda kullanılsa da kuramsal açıdan farklı içeriktedir (Ertuğrul, 2008: 143). Özellikle finansal piyasalarda önemli sorunlardan birisi, fiyatın ne ölçüde gerçekçi olduğudur. Bir finansal varlığın piyasa fiyatı ile çeşitli yöntemlerle belirlenen varlığın gerçek değeri arasındaki ilişki çok önemlidir. Gerçek değer, finansal varlığın olması gereken değeridir. Finansal varlıkların fiyatı, arz ve talep çerçevesinde piyasa koşullarına göre dalgalı seyretmektedir. Alıcı ve satıcıların alım-satım istekli olduğu çeşitli fiyatlardan değişik güç ve dirençte yeni dengelerin oluşması, aslında gerçek değer bulunduğuna değil, sürekli olarak arandığına bir işarettir. Güçlü formda etkin piyasalarda aranan değer gerçek değere yaklaşması mümkünken; etkin olmayan piyasalarda piyasa fiyatının aranan gerçek değerden uzaklaştığı gözlemlenmektedir (Gürbüz ve Ergincan, 2008: 5). Sağlam bir yatırım önermelerinden birisi, bir yatırımcının bir varlığa ederinden daha fazla ödeme yapmamasıdır. Bu önerme kabul edilirse en azından varlıkları satın almadan önce değerlendirme yapmak gerekmektedir (Damodaran, 2011: 15). Geniş anlamda ise değerlendirme, para dışındaki ekonomik varlıkların değerinin parasal olarak ifadesi; bir kişiye, kuruma ya da şirkete ait arsa, bina, makine, teçhizat, mal stoku şeklindeki aktiflerinin ve pasiflerinin değerinin tahminidir (Seyidoğlu, 1992: 142).

Değerlemede geçmiş bilgilere bakmanın nedeni ise gelecekle ilgili doğru ve gerçekçi varsayımlar oluşturabilmek içindir (Öztürk, 2009: 15).

Finans yazınında en çok araştırma yapılan konulardan birisi olan şirket değerlemenin, genel kabul gören bir standart formülü bulunmamaktadır. Bunun nedeni ise değer ve değerlendirme kavramlarının içerdiği öznel yargılardır (İvgen, 2003: 37). Şirket değerlendirme çalışmaları, mevcut değerlendirme yaklaşımları ile yürütülmektedir. Bu bağlamda, Türkiye’de holding şirketlerinde geçmiş dönem finansal veriler kullanılarak şirket değerinin nasıl tahmin edilebileceğine yönelik motivasyon, bu araştırmanın kaleme alınmasındaki temel sürükleyicidir. Ayrıca, yapılması planlananların geleneksel değerlendirme yaklaşımları, istatistik ve ekonometrik yöntemler dışında; makine öğrenmesi temelli algoritmalar aracılığı ile yapılması araştırmanın özgünlüğü açısından önemli bir unsurdur.

Bu çerçevede bu çalışmada, Borsa İstanbul Holding ve Yatırım Endeksi’nde (XHOLD) yer alan 12 şirketin bağımsız değişkenleri oluşturan 25 adet finansal oran/verinin, bağımlı değişken olarak şirket değerini temsil eden piyasa değerini tahmin etme gücü makine öğrenmesi algoritmalarından Yapay Sinir Ağları (YSA), Destek Vektör Makinesi (DVM), Karar Ağaçları (KA) ve Rastgele Orman (RO) ile sınanması amaçlanmıştır. Ayrıca, bu araştırma ile yatırımcılara ve analistlere hisse senedi yatırımlarında ve şirket değerlendirme süreçlerinde makine öğrenimi algoritmaları ile geleneksel değerlendirme yaklaşımlarına kıyasla farklı bir bakış açısı oluşturulmaya çalışılmıştır.

Bu çalışmada giriş bölümü sonrasında sırası ile makine öğrenmesi ve algoritmalar, literatür incelemesi, araştırmanın veri seti, kurulan modeller ve ampirik bulgular detaylandırılmıştır. Son kısımda ise sonuç bölümü ile araştırma tamamlanmıştır.

2. Makine Öğrenmesi ve Algoritmalar

Bilgisayarlı görme, doğal dil işleme, örüntü tanıma, sınıflandırma ve biyoinformatik gibi alanlarda kullanılan makine öğrenmesi, giriş verileri ile çıkış verileri arasında doğrusallığın olmadığı problemleri çözebilmek için geliştirilmiş esnek hesaplama sistemidir (Metlek ve Kayaalp, 2020: 2). Örneklerden öğrenen bir yazılım olan makine öğrenmesinin temeli, çeşitli gözlemler sonucu elde edilen verilerin bilgisayarlar ile işlenerek, bu gözlemlerin içerisinde yer alan örüntülerin keşfedilip tanımlanabilmesine dayanmaktadır (Hamel, 2009: 4; AYTEKİN, 2021: 88). Öğrenme işlemi yapacak olan makine için süreç üç temel aksiyondan oluşmaktadır. Birincisi, verilerin gözlenmesi ve hafızaya alınarak daha sonra yapılacak değerlendirme için hatırlamanın sağlanmasıdır. İkincisi, çıkarım aşaması olup verilerin sunuma imkân verecek şekilde dönüştürülmesidir. Sonuncu ise genelleştirme olarak adlandırılmakta ve aksiyonun alınmasına temel oluşturan çıkarım yapılmış verilerin kullanılmasıdır (Shwartz ve David, 2014: 19-20). Daha ayrıntılı bakılacak olursa, verilerin toplanması ile başlayan makine öğrenmesi uygulaması için analiz edilmeye konu veri elektronik ortama aktarımının yapılması

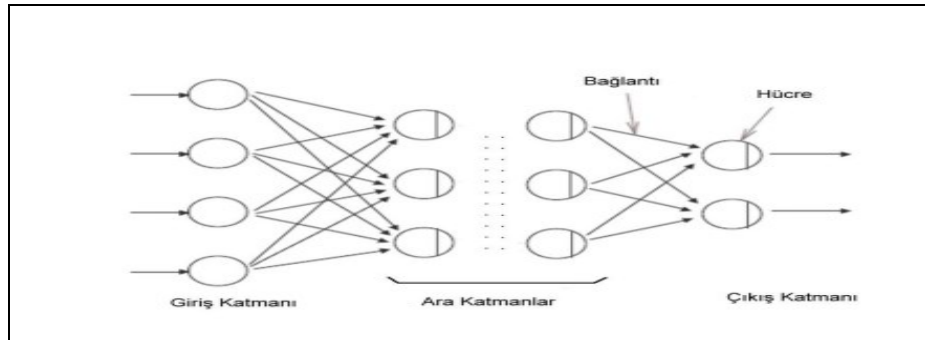
gerekmektedir. Makine öğrenimi algoritmasının kalitesi aslında elde edilen verinin kalitesine bağlıdır. Verinin incelenmesi ve hazırlanması aşaması büyük ölçüde insan müdahalesini ve etkisini içermektedir. Analistin veriyi anlaması ve gerekli düzeltmelerin yapılması elzem bir konudur. Modelin eğitilmesi sürecinde, öncelikle veriden öğrenilmek istenen şey açıkça tanımlanmalıdır. Aslında hedeflenen amaç, kullanılacak algoritmayı da ortaya koymaktır. Modelin performansının değerlendirilmesi sürecinde, modelin türüne göre test verileri yardımı ile modelin almış olduğu karar test edilmektedir. Son olarak test verileri ile sınanmakta olan modelin gerekli performansı göstermediği durumda, modelin değiştirilebilmesi, veri eklemelerinin yapılabilmesi ya da her ikisinin yapılması alternatifler arasındadır (Zocca vd., 2017: 9-10). Ham verinin bilgiye dönüşüm süreci, aslında ham veriler arasında gizli kalmış ilişkilerin ortaya çıkarılması olarak tanımlanabilir. Bilgiye dönüşüm sürecinde verinin elde edilmesinin yanında biçim uyumsuzlukları, veri tutarsızlıkları, eksik ve yanlış girilmiş veriler öncelikli olarak ele alınmalıdır. Bu problemler veri ön işleme (data preprocessing) olarak adlandırılan süreçten sonra makine öğrenmesi algoritmaları ile analizlerin yapılarak ham veriden bilgiye dönüşüm süreci tamamlanmalıdır (Uğuz, 2021: 69).

Bu kısımda Yapay Sinir Ağları, Destek Vektör Makineleri, Karar Ağaçları ve Rastgele Orman algoritmalarının teorik altyapıları ve özellikleri kısaca özetlenmektedir.

2.1. Yapay Sinir Ağları (YSA)

Biyolojik sinir sisteminden esinlenilmiş olan YSA, belirsiz ve karmaşık veri kümelerinden anlamlı çıkarımlar yapma yeteneğine sahiptir (Zakaria vd., 2014: 7). YSA, bir takım girdi ve çıktı sinyalleri arasındaki ilişkiyi insan beyninin verdiği tepkilere benzeterek modelleyebilmektedir (Witten vd., 2011: 233). Bu bilgiler çerçevesinde YSA, insan beynini ve biyolojik sinir sistemini bilgisayarlar aracılığı ile taklit etmeye çalışan, öğrenen ve öğrendiklerini hafızasında saklayan, genelleme yeteneğine sahip, birçok temsili sinir hücresinin, birbirine bağlantı ağırlıkları ile bağlanması ile oluşturulan bir sistemdir (Yakut, 2012: 53).

Şekil 1: Çok Katmanlı YSA Mimarisi




Kaynak: Çayıroğlu, 2015: 5.

Bir yapay sinir ağı, giriş katmanı, ara (gizli) katman ve çıktı katman olmak üzere üç katmandan oluşmaktadır. Giriş katmanı, dış dünyadan verileri alarak ara katmanlara iletmekle sorumludur. Dış dünyadan giriş katmanına gelen girdiler herhangi bir işleme uğramadan bir sonraki katmana iletilmektedir. Ara (gizli) katman, kendisine bilgileri işleyerek çıktı katmanına iletmekle sorumludur. Bir ağın birden fazla ara katmanı olabilir. Ara katmanların ve bu katmanlarda bulunan nöronların sayısının artması hesaplama karmaşıklığını ve süresinin arttırmasına rağmen karmaşık YSA problemlerinin çözümüne katkı sunmaktadır. Çıktı katmanı ise ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan veri seti için üretilmesi gereken çıktıyı üretmektedir (Öztemel, 2006: 52-53; Çayiroğlu, 2015: 5). Sadece giriş katmanı ve çıktı katmanından oluşan YSA modellerine Tek Katmanlı Sinir Ağları (Single Layer Neural Networks), giriş katmanı ile çıkış katmanı arasında ara katmanların eklenmesiyle oluşan YSA mimarisine ise Çok Katmanlı Sinir Ağları (Multi-Layer Neural Networks) olarak ifade edilmektedir (Uğuz, 2021: 207). Şekil 1’de Çok Katmanlı YSA mimarisi görülmektedir. Bir YSA yapısı kurgulanırken genel kabul görmüş bir standart bulunmamaktadır. Karmaşık problemlerin çözümünde, gerekli olan gizli katmanların sayısından daha az gizli katman kullanılması bu problemlerin çözümünde yetersizliğe neden olabilmektedir. Girdi ve çıktı katmanlarının belirlenmesinde bu şekilde bir sorun ile karşılaşılmazken, esas sorun gizli katmanlardaki nöron sayısının seçiminde ortaya çıkmaktadır. Gizli katmanlarda kaç nöronun bulunacağına ise deneme ve yanılma yolu ile karar verilmelidir (Detienne vd., 2003: 244).

2.2. Destek Vektör Makineleri (DVM)

Popüler sınıflandırma tekniklerinden birisi olan DVM matematiksel konulara dayalı doğrusal ve doğrusal olmayan sınıflandırma çalışmalarına olanak sağlayan bir makine öğrenimi algoritmasıdır (Uğuz, 2021: 237). Temeli istatistiksel öğrenme modeline dayanmaktadır. Aykırı değerlerin tespiti, sınıflandırma ve regresyon çalışmalarında kullanımı söz konusudur (Vercellis, 2009: 262). Bir hiper düzlem konsepti olan DVM, doğrusal bir düzlemde yer alan sınıflar arasındaki en uzun mesafeyi (marjı-kenar payı) bulmayı amaçlayan bir yöntemdir. Bu yöntem destek vektörlerini baz alarak ve çekirdek (kernel) fonksiyonlarını kullanarak doğrusal olmayan problemlerin çözümüne yardımcı olabilmektedir (Witten vd., 2011: 228). Şekil 2’de görüleceği üzere hiper düzlem her iki sınıfın tam ortasına konuşlanmaya çalışmaktadır. Doğrusal olarak ayrılabilen iki farklı sınıf arasında sonsuz sayıda hiper düzlem geçebilmektedir. DVM’nin amacı, iki sınıf arasındaki marjı (maksimum sınır) en yükseğe çıkarmaktır. Örneklem uzayında bulunan sınıf değerleri her zaman keskin hatlarla ayrılmayabilir, yani doğrusal olmayan bir formda bulunabilir. DVM bu durumda çekirdek fonksiyonları kullanarak destek vektörlerini tespit eder. Bu işlemi gerçekleştirebilmek için haritalandırma (mapping) kullanılmaktadır (Olson ve Delen, 2008: 111).

Şekil 2: DVM'nin Düzlem Üzerindeki Gösterimi



Kaynak: Aggarwal ve Singh, 2015: 246.

DVM, doğrusal olarak ayrılabilen ve ayrılamayan sınıflandırma problemlerinin yanı sıra regresyon problemlerinde de uygulanabilmektedir. Hem sınıflandırma hem de regresyon işlemlerinde, öğrenme problemi ikinci dereceden amaç fonksiyonuna sahip bir optimizasyon problemi formunda temsil edilmektedir. DVM regresyon yöntemlerindeki temel fikir, eldeki eğitim verilerinin karakterini mümkün olduğunca gerçeğe yakın bir şekilde yansıtan ve istatistiksel öğrenme teorisine uyan doğrusal ayırıcı fonksiyonun bulunmasıdır. Sınıflandırmaya benzer bir şekilde regresyonda da doğrusal olmayan durumların işlenebilmesi için çekirdek fonksiyonları kullanılmaktadır. Çekirdek fonksiyonlarının kullanımı ile DVM, yüksek boyutlu nitelik uzayında doğrusal bir forma dönüşmektedir (Çomak, 2008: 37-38). Destek vektör regresyonu uygulamalarında yaygın şekilde kullanılan çekirdek fonksiyonları Radyal Temelli Fonksiyon (RBF), Polinom, Doğrusal ve Sigmoid olmak üzere kategorize edilebilir. Literatürde, diğer çekirdek fonksiyonlara kıyasla RBF çekirdek fonksiyonunun daha tatmin edici sonuçlar elde ettiği tespit edilmiştir (Açıkkar ve Sivrikaya, 2020: 19).

2.3. Karar Ağaçları (KA)

Ağaç tabanlı bir öğrenme algoritmasına sahip olan KA, regresyon ve sınıflandırma problemlerinin çözümünde etkin şekilde kullanılmaktadır. Yapısı itibari ile ağaca benzeyen, problemleri çözerken en tepeden en aşağıya doğru ilerleyen bir strateji sunar. Akış diyagramını andıran bu stratejide, her bir düğüme ait nitelik değerleri ölçülmekte ve bu ölçüm sonucunda elde edilen sonuca göre dallanmalar oluşmaktadır. KA, belirlenen bir ayrılma kriteri eşliğinde kök düğüm ile başlar, kök düğüm daha sonra belirlenen kriter eşliğinde ara düğümlere ayrılmakta ve son olarak bu ayrılmalar yaprak düğümleri ile sonlanmaktadır. KA akış şemasında, en üst yapı kök, orta yapı dal ve en son yapı ise yaprak olarak şekillenmektedir (Kantardzic, 2001: 139-140; Han vd., 2012: 332; Özkan, 2013: 52). Veri setinin büyüklüğüne ve niteliğine göre ağaç dallanması karmaşık hale gelebilmektedir. Bu durumun engellenmesi ve KA algoritmasının ezber dayalı öğrenme sorunu yaşamaması için budama işlemi gerçekleştirilmelidir. Budama işlemi, az sayıda nesne bulduran yaprak düğümlerinin KA grafiğinden atılması olarak

açıklanabilir. Budama işleminin dengeli yapılması gerekir, yapılmadığı takdirde örnek uzay hakkında yeterli derecede bilgi alınamaması sorununa yol açmaktadır. KA algoritmasında bölünme kriterleri de regresyon ve sınıflandırma problemleri için farklılık göstermekte, yani algoritma seçimi hedef değişkenin tipine göre yapılmaktadır. Sınıflandırma Hatası Endeksi, Entropi Endeksi, Gini Endeksi, Twoing ya da Ordered Twoing kategorik değişkenler için kullanılan algoritmalar iken; sürekli değişkenler için ise En Küçük Kareler yöntemi söz konusudur (Akpınar, 2014: 218; Özdemir, 2017: 109).

2.4. Rastgele Orman (RO)

RO, her ağacın bağımsız olarak örneklendiği ve ormandaki tüm ağaçlar için aynı dağılıma sahip rastgele bir vektörün değerlerine bağlı olacak şekilde ağaç tahmincilerinin birleşimidir (Breiman, 2001: 5). Temelinde karar ağaçları olan RO, birbirinden bağımsız şekilde oluşturulan karar ağaçlarının bir araya gelmesiyle oluşturulan orman ile tahminlerin birleştirilmesi amaçlanmaktadır (Atasever, 2011: 31). RO, sınıflandırma ve regresyon problemlerinin çözümünde kullanılmakta ve eğitim sırasında çok sayıda karar ağacı oluşturularak istenilen sınıflandırmayı ya da tahmini ortaya koymaktadır. Veri setindeki “sınıf değişkeni” kategorik ise sınıflandırma, sürekli ise regresyon ağaçları oluşturulmaktadır (Akman vd., 2011: 37; Er, 2020: 27). RO algoritması, veri setine ait tüm değişkenler arasından en iyi dalı kullanarak her bir düğümü dallara ayırmak yerine, her bir düğümde rastgele olarak seçilen değişkenler arasından en iyisini kullanarak her bir düğümü dallara ayırmaktadır. Her bir veri seti orijinal veri setinden yeniden örnekleme kullanılarak üretilmektedir (Akar ve Güngör, 2012: 141). RO algoritmasında, torbalama ve rastgele değişken seçimi işlemleri birbiri ardına uygulanmaktadır. Mevcut eğitim setinden oluşturulacak her yeni eğitim seti için rastgele değişken seçimi yapıldığından ormanda bulunan ağaçlarda budama işlemine gerek kalmamaktadır (Breiman, 2001: 11). RO algoritmasının bu özelliği, KA algoritmasına göre en iyi avantajıdır (Pal, 2005: 218). RO algoritmasında ağaçlar, CART algoritması tarafından oluşturulmaktadır. CART algoritması veri setinin hangi değişkenden başlayarak dallara ayrılacağına Gini İndeksi ile karar vermektedir (Akman vd., 2011: 37). RO algoritmasının uygulama sürecinde kullanıcılardan Ağaç Sayısı (N) ve ağaç yapısının oluşturulma sürecinde her düğümde kullanılan Değişken Sayısı (m) olmak üzere iki parametre istenmektedir (Breiman, 2001: 6).

2.5. Regresyon Problemleri için Performans Değerlendirme Ölçütleri

Bir makine öğrenmesi modelinin başarısının ölçülmesi ya da modelin iyi bir model olduğunun kararının verilmesi bazı performans ölçüm metrikleri ile kanıtlanmalıdır. Denetimli makine öğrenimi algoritmaları sınıflandırma ve regresyon problemleri şeklinde ayrıma tabi tutulurken, her iki problem tipinin performans değerlendirme metrikleri de farklılaşmaktadır. Bu çalışmada regresyon problemlerinin performansının ölçülmesinde Belirleme Katsayısı- R^2 (Determination Coefficient R-Squared), Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Ortalama Kare Hata Karekökü (Root Mean Squared Error, RMSE),

kullanılmıştır. Tablo 1’de araştırmada kullanılan performans metriklerini matematiksel gösterim ve tanımlarına yer verilmiştir.

Tablo 1: Araştırmada Kullanılan Performans Metrikleri

Performans Metriği	Matematiksel Gösterim	Metrik Tanımı
Belirleme Katsayısı-R ²	$R^2 = K_{TR} / K_{TY}$	Bağımlı değişkendeki değişimin yüzde kaçının bağımsız değişken tarafından açıklanabildiğini konusunda bilgi vermektedir. 0 ile 1 arasında bir değer almaktadır.
Ortalama Mutlak Hata	$MAE = \frac{1}{n} \sum_{j=1}^n e_j $	Veri setindeki gerçek değerler ile tahmin değerleri arasındaki farkların mutlak değerlerinin toplamı alınarak sonucun örneklem sayısına bölünmesi ile bulunur.
Ortalama Kare Hata Karekökü	$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n e_j^2}$	Ortalama kare hata (MSE) değerinin karekökünün alınması ile bulunur.

Kaynak: <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>
Alpar, 2013: 435.

3. Literatür İncelemesi

Bu kısımda, literatürde makine öğrenmesi algoritmaları ile şirket değerlendirme ilişkisini ele alan araştırmalara yer verilmiştir.

Kryzanowski vd. (1993), şirketlerin finansal, sektörel ve ekonomiye ait verileri ile bir sonraki yıla ait getiri arasındaki ilişkiyi YSA yöntemi ile tahminlenmesini amaçlamışlardır. Örneklemi ise 49 sektöre ait halka açık 120 şirket oluşturmaktadır. Bilanço ve gelir tablolarından hesaplanan 14 finansal oran kullanıldığı araştırma bulgularına göre YSA, pozitif/negatif getirilerin %72'sini doğru bir şekilde sınıflandırdığı görülmüştür.

Olson ve Mossman (2003), Kanadalı şirketlerin hisse senedi getirini YSA, En Küçük Kareler (EKK) ve Lojistik Regresyon yöntemleri ile ölçmüşlerdir. 1976-1993 yıllarına ait verilerin kullanıldığı araştırmada, 61 adet finansal/muhasebe oranı bağımsız değişken, bir sonraki yılın hisse senedi getirileri bağımlı değişken olarak kullanılmıştır. Araştırma bulgularına göre YSA'nın diğer tekniklere göre daha iyi tahmin performansı göstermiştir.

Eakins ve Stansell (2003), 20 yıllık bir dönemi kapsayan araştırmalarında bir dizi finansal orana dayalı tahminler gerçekleştirmek için sinir ağı modelleme prosedürlerini kullanarak üstün yatırım getirilerinin elde edilip edilemeyeceğini tespit etmeye çalışmışlardır. Araştırma bulgularına göre YSA kullanılarak seçilen portföylerin getirilerinin S&P 500 ve Dow Jones Endeks getirilerinden daha iyi olduğu tespit edilmiştir.

Hsiao vd. (2006), Tayvan MSCI 50 borsa endeksinde yer alan şirketlerin hisse senedi getirilerini tahmin etmişlerdir. Düşük, orta ve yüksek büyüme gösteren şirketler, geri yayımlı YSA tekniği ile piyasa değerleri tahmin edilmeye çalışılmıştır. 12 adet finansal oran/muhasebe verisinin kullanıldığı araştırma

bulgularına göre YSA'nın yatırımcılara hisse senedi satın alıp almama konusunda sinyal gönderebildiği tespit edilmiştir.

Albanis ve Batchelor (2007), YSA ile diğer istatistiksel teknikleri karşılaştırdıkları araştırmalarında Londra Borsası'ndaki 700 hisse senedini finansal oranlar yardımı ile sınıflandırmışlardır. YSA ile vektör niceleme, döngüsel bölümlenme, bir kural çıkartma algoritması ve doğrusal ayırma analizi yöntemleri kullanılmıştır. Yıllık bazda ay sonu fiyatlarının hisse senedi getiri olarak kullanılan araştırma bulgularına göre YSA ile doğrusal ayırma analizinin sınıflandırmada aynı başarıyı elde ettiği tespit edilmiştir.

Wilimowska ve Krzysztoszek (2013), YSA ile şirket değerlendirme modeli oluşturmuşlardır. Polonya'da bir tavukçuluk şirketinin örneklem alındığı araştırmada, sinir ağının oluşumunda girdi değişkenleri olarak Varşova borsası endeksi verisi, üretim kapasitesi, ekonomik durum, ürünün maliyet ve fiyat verileri, tüketim verisi, ihracat verisi, pazarlama harcamaları, şirketin pazardaki payı, salgın hastalık riski, özkaynak kârlılık oranı ve on büyük müşteriye satış oranı alınmışken; çıktı değişkenleri ise nakit akışı ve net varlık tutarları seçilmiştir. Girdi değişkenleri, değerlerin yol göstericileri; çıktı değişkenleri ise şirket değerini temsil etmektedir. Değerlendirme ölçütü olarak ise RASE (Relative Average Squared Error) ve MSE kullanılmıştır. Araştırmada, faktörlerin tahmin edilen değerlerinin şirketin net varlık değerini ve nakit akışını belirlediği varsayılmıştır. Analiz bulgularında, nakit akışı ve net varlık değeri için sırası ile RASE değeri %23,42 ve %7,49 hata ölçümü tahmin edilmiştir. YSA'nın net varlık değerini tahmin etmede başarılı olduğu görülmüştür.

Ekşi vd. (2014), İstanbul Menkul Kıymetler Borsası (İMKB) metal sanayi şirketlerinin 2004-2008 dönemini kapsayan verileri ile Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) metodu kullanılarak şirket değerlerinin tahmin edilmesi amaçlanmıştır. Kısa ve uzun vadeli yükümlülükler ve özkaynaklar girdi değişkenleri; şirket değerini temsilen piyasa değeri çıktı değişkeni olarak kullanılmıştır. Değerlendirme metriği olarak ise R^2 , MSE ve MAE kullanılmıştır. Analiz bulgularında, ANFIS modelinin şirketin $t+1$ dönemindeki piyasa değerini küçük hata oranları ile tahmin ettiği görülmektedir. Hem eğitim hem de test verilerinde tahmin edilen şirket değerleri ile gerçek değerler arasındaki korelasyon oldukça yüksek olduğu görülmüştür (Eğitim R^2 : 0,998-Test R^2 : 0,987).

Kuzey vd. (2014), 1997-2011 dönemini ele aldıkları araştırmalarında veri madenciliği tekniklerini kullanarak çok ulusluluk ile şirket değeri arasındaki ilişkiyi incelemişleridir. Çok ulusluluğu temsilen yabancı satışların oranı, şirket büyüklüğü, kaldıraç oranı, satış büyümesi, sermaye yapısı, karlılık oranı, varlık yapısı/varlık büyüme oranı ve likidite finansal değişkenleri olmak üzere toplam 15 bağımsız değişken ile şirket değerini temsilen ise şirketin piyasa değeri ve PD/DD bağımlı değişkenler olarak kullanılmıştır. KA ve YSA algoritmalarının kullanıldığı araştırmada bağımsız değişkenler arasında çok ulusluluğun şirket değerini sadece

orta düzeyde belirlediği tespit edilmiştir. Ayrıca, şirket büyüklüğü, kaldıraç, likidite ve kârlılık gibi diğer finansal değişkenlerin şirket değerini etkilediği görülmüştür.

Milosevic (2016), 2012-2015 dönemine ilişkin çeyrek dönemlik verilerle S&P 1000, FTSE 100 ve S&P Europe 350 gibi endekslerden toplamda 1739 hisse senedinin fiyat hareketini tahmin etme görevini iyi ya da kötü şeklinde ikili bir sınıflandırma yapabilen bir model kurmuşlardır. Araştırmada, C4.5 KA, DVM, JRip, RO, Lojistik Regresyon, Naive Bayes, Bayesian Networks algoritmaları kullanılmıştır. 28 finansal oranın kullanıldığı sınıflandırma probleminde RO algoritması %75,1 duyarlılık (recall, sensivity), kesinlik (precision) ve F-skoru en iyi performansı gösteren algoritma olmuştur. İlgili araştırmada özellik seçimi yardımı ile 11 finansal oranla uygulandığında RO algoritması %76,5 oranında duyarlılık, kesinlik ve F-skoru ölçüm metrikleri ile en iyi performansı göstererek özellik seçimi öncesine göre daha iyi performans sağlamıştır.

Zhang vd. (2016), yaklaşık 5000 birleşme ve devralma (M&A) işlemine dayanan araştırmalarında petrol ve enerji şirketlerinin değer tahmininde K-En Yakın Komşu, KA, DVM, YSA, AdaBoost ve RO algoritmalarını kullanmışlardır. Araştırmada şirket değeri bağımlı değişken; şirket büyüklüğü, aktif devir hızı, faiz ve vergi öncesi kâr (FVÖK), net kâr marjı, aktif kârlılık oranı, özkaynak kârlılık oranı, borç ödeme oranı, şirketin yatırım büyümesi değişimi (capex), toplam borç/toplam aktifler, şirket tipi, hedef şirketin uyruğu, M&A türü, satın alma yılı, satın almaya ilişkin işlem ücreti bağımsız değişken olarak kullanılmıştır. Hem petrol hem de enerji şirketleri için YSA'nın tahmin hatasının üç ölçüm teriminin (MAPE, MAE, RMSE) tümünde en düşük olduğunu tespit edilmiştir. YSA, petrol endüstrisi için diğer beş ML algoritmasından en az %18 daha iyi performans gösterirken, enerji endüstrisi için diğerlerinden %19 daha iyi performans göstermiştir.

Lee ve Kwon (2017), ABD'deki yüksek teknoloji odaklı küçük ve orta ölçekli işletmelerde (KOBİ) stratejik faktörlerin firma performansı üzerindeki etkisini incelemek için sinir ağlarını kullanan uyarlanabilir bir performans modeli oluşturmuşlardır. Geri Yayımlı Sinir Ağının (BPNN) yöntemi ile öncelikle yüksek teknoloji segmentlerini yüksek ve düşük performans şeklinde iki performans grubuna ayırarak daha iyi şirket performansı için stratejik belirleyicilerin önemi tespit edilmeye çalışılmıştır. Oluşturulan modelde şirket piyasa değeri, aktif kârlılık oranı, Ar-Ge harcamalarının defter değeri/toplam satış oranı, cari oran, satış büyümesi, stok devir hızı, ortalama alacak tahsil süresi finansal değişken/faktörler olarak kullanılmıştır. Ampirik sonuçlar, modelin başarılı bir şekilde uygulanabildiğini, satış büyümesi, Ar-Ge yoğunluğu ve cari oranın teknoloji odaklı KOBİ'lerin piyasa değerinin belirleyicileri oldukları tespit edilmiştir.

Pao vd. (2020), araştırmalarında şirket değerini tahmin etmek için Extreme Gradient Boosting (XGBoost) makine öğrenimi algoritmasını kullanmışlardır. Doğrusal olmayan XGboost modelleri, bulguları açısından doğrusal panel regresyon modelleri ile karşılaştırılmıştır. Şirket değeri Tobin Q indikatörü tarafından temsil edilmektedir. 383 Tayvanlı şirketin 2014-2017 dönemine ilişkin

yıllık panel verileri kullanılmıştır. Tobin Q indikatörü kullanılarak oluşturulan model için %0,43 MAPE ile eğitilmiş ağaç topluluğu modeli, %17,54 MAPE ile doğrusal panel regresyon modelinden çok daha bir tahmin ortaya koymaktadır.

Chong vd. (2020), araştırmalarında Çin’de 3500 borsaya kayıtlı şirketin faaliyet verilerine dayanarak işletmelerin yatırım değerini incelemişlerdir. DVM, Genelleştirilmiş Lineer Model, KA, RO, Gradient Boosting KA ve Derin Öğrenme algoritmalarının kullanıldığı araştırmada, kapsamlı bir değerlendirme yapabilmek için finansal ve finansal olmayan değişken seti tercih edilmiştir. Accuracy (doğruluk), RMSE ve MAE kriterleri dikkate alındığında en iyi performansı Gradient Boosting KA algoritması göstermiştir. Ayrıca araştırma bulgularına göre finansal göstergelerin ağırlığının finansal olmayan göstergelerden çok daha fazla olduğu görülmüştür. Finansal göstergelerdeki en büyük ağırlık ödeme gücüne ait iken; finansal olmayan göstergelerde en büyük ağırlık şirketin yaşıdır. Genel olarak, en önemli dört gösterge patent sayısı, brüt kâr marjı, cari borç oranı ve hızlı oran şeklindedir. Bu göstergeler, işletmelerin yatırım değeri puanı ile pozitif bir ilişki içindedir.

Peştere (2021), 2006-2019 dönemi BİST’te işlem gören 12 çimento şirketinin İndirgenmiş Nakit Akımları (İNA) yöntemi ile hesaplanan şirket değerleri, bu şirketlerin piyasa değerleri ile kıyaslanmıştır. İlgili derecelendirme analizinde 47 adet finansal orandan ve şirket değerinden yararlanılmış, makine öğrenimi yöntemlerinden K-Ortalama ve K-en Yakın Komşu kullanılarak değere dayalı derecelendirmenin geçerliliği sınanmıştır. K-en Yakın Komşu algoritma sonuçlarına göre değere dayalı derecelendirmenin performansının %93,5, yalnızca finansal oranların kullanıldığı modelin %50, İNA yöntemi ile buluna değer ile finansal oranların birlikte kullanıldığı modelin %93,94 performans oranına sahip olduğu, şirket piyasa değeri ile finansal oranların birlikte performansının %87,88 olduğu tespit edilmiştir.

Literatür incelemesini genel olarak değerlendirmek gerekirse, şirket değer tahmini uygulamalarında kullanılan makine öğrenmesi algoritmalarında hem sınıflandırma hem de regresyon problemlerinde YSA algoritmasının performans başarısının diğer algoritmalara göre daha yüksek olduğu görülmektedir.

4. Araştırmanın Veri Seti

Araştırma evrenini 2011:Q1-2019:Q4 döneminde BİST XHOLD endeksinde bulunan 43 şirket oluşturmakta ve sağlıklı veri setine erişilen 12 holding şirketi örneklem olarak alınmıştır. Araştırmaya dahil edilen holding şirketlerinin listesine Tablo 2’de yer verilmiştir.

2011:Q1-2019:Q4 aralığında üçer aylık dönemler itibariyle toplamda 36 çeyreklik dönem araştırmanın zaman dilimini oluşturmaktadır. Veri seti Kamu Aydınlatma Platformu (KAP) ile şirketlerin piyasa değerlerinin hesaplanmasındaki hisse senedi kapanış fiyatı Yahoo Finance veri tabanlarından temin edilmiştir. Makine

öğrenmesi algoritmalarından yeterli tahmin gücü elde edebilmek adına istikrarlı bir zaman aralığının seçimi elzemdir.

Tablo 2: Araştırmaya Dahil Edilen Holding Şirketleri

Sıra	Şirket Hisse Kodu	Şirket Adı
1	AGHOL	Anadolu Grubu Holding A.Ş.
2	ALARK	Alarko Holding A.Ş.
3	KCHOL	Koç Holding A.Ş.
4	DOHOL	Doğan Holding A.Ş.
5	SAHOL	Hacı Ömer Sabancı Holding A.Ş.
6	İHLAS	İhlas Holding A.Ş.
7	İTTIFH	İttifak Holding A.Ş.
8	NTHOL	Net Holding A.Ş.
9	TKFEN	Tekfen Holding A.Ş.
10	TAVHL	Tav Havalimanları Holding A.Ş.
11	GSDHO	GSD Holding A.Ş.
12	IEYHO	Işıklar Enerji ve Yapı Holding A.Ş.

Belirlenen dönem aralığının seçiminde Kaderli ve Küçükkaya (2012), Kaya ve Kaygısız (2015) çalışmalarında açıklandığı üzere ABD’de ortaya çıkan 2008 küresel finans krizinin dünya ekonomilerinde yaşattığı türbülans ve ülkelerin makroekonomik göstergelerinin bozulması, bu krizin şirketlerde yarattığı tahribat ve bunun sonucunda şirket bilanço/gelir tablolarının anormal derecede bozulması en önemli etkidir. Küresel finans krizinin etkisinin 2010-2011 yıllarına doğru bir nebze azalması ve şirket bilanço/gelir tablolarının tekrar istikrarlı bir yapıya kavuşması nedeni ile araştırmanın başlangıç dönemi 2011:Q1 olarak alınmıştır. Son dönem olarak 2019:Q4 alınmasının nedeni ise Çin’in Wuhan kentinden dünyaya yayıldığı bilinen Covid-19 pandemisinin Türkiye’de Mart 2020 ortalarında görülmesi ve koronavirüsün yayılım göstermesi ile finansal piyasalarda yine bir türbülansa neden olması, dünya borsaları ile birlikte Borsa İstanbul’unda bu durumdan oldukça güçlü etkilenmesidir. Araştırmada kullanılan veri setindeki değişkenler şirketlere özgü parametrelerdir; ülkenin makroekonomik göstergeleri olarak bilinen enflasyon, döviz kuru, faiz oranları vb. değişkenler şirketlerin kontrol edemediği parametreler olduğundan çalışma kapsamına dahil edilmemiştir.

Araştırmada kullanılan finansal oranlar/veriler Tablo 3’te sunulmuştur. Her bir şirket için bir adet ‘‘Piyasa Değeri’’ bağımlı değişken olarak; 25 adet bağımsız değişken toplamda ise 26 adet değişkenden oluşan bir veri tabanı oluşturulmuştur.

Şirket değerini temsilen ‘‘Piyasa Değeri’’ bağımlı değişken olarak kullanılmış olup; bu durum literatürde Hsiao vd. (2006), Özaltın (2016), Birgili ve Düzer (2010), Büyükşalvarcı ve Uyar (2012), Kuzey vd. (2014), Gümüş vd. (2017), Özçalık ve AYTEKİN (2017), Lee ve Kwon (2017), Özdemir ve Öncü (2018), Akyüz

ve Yıldırım (2019), Uyar ve Sarak (2020), Avcı (2020) çalışmalarına dayandırılarak belirlenmiştir.

Tablo 3: Araştırmada Kullanılan Finans Oranlar/Veriler

Bağımsız Değişkenler		Kısaltma	Açıklama
Likidite Oranları	Cari Oran	LİK1	(Dönen Varlıklar) / (Kısa Vadeli Borçlar)
	Likit Oran	LİK2	(Dönen Varlıklar- Stoklar) / (Kısa Vadeli Borçlar)
	Nakit Oran	LİK3	(Nakit ve Nakit Benzeri Varlıklar) / (Kısa Vadeli Borçlar)
Mali Yapı-Borçlanma Oranları	Borç/Kaynak Oranı	MALİ1	
	Özsermaye/Aktif	MALİ2	
	Mali Borç/Toplam Borç	MALİ3	
	Kısa Vade Borç/Aktif	MALİ4	
Faaliyet Oranları	Stok Devir Hızı	FA1	(Satılan Malın Maliyeti / Ortalama Stoklar)
	Alacak Devir Hızı	FA2	(Net Satışlar / Ortalama Ticari Alacaklar)
	Aktif Devir Hızı	FA3	(Net Satışlar /Aktif Toplam)
	Dönen Varlık Devir Hızı	FA4	(Net Satışlar /Dönen Varlıklar)
Kârlılık Oranları	Brüt Kâr Marjı (%)	KAR1	(Brüt Kâr) *100 / (Net Satışlar)
	Esas Faaliyet Kâr Marjı (%)	KAR2	(Esas Faaliyet Kârı) *100 / (Net Satışlar)
	Net Kâr Marjı (%)	KAR3	(Net Kâr) *100 / (Net Satışlar)
	Aktif Kârlılık Oranı (%)	KAR4	(Net Kâr) *100/ (Aktif Toplam)
	Özsermaye Kârlılık Oranı (%)	KAR5	(Net Kâr) *100/ (Özsermaye)
Borsa Performans Oranları	Fiyat/Kazanç Oranı	BOR1	(Hisse Senedi Fiyatı) / (Hisse Başı Kâr)
	Piyasa Değeri/Defter Değeri (%)	BOR2	(Piyasa Değeri) / (Defter Değeri)
	Hisse Başı Kâr	BOR3	(Net Kâr / Ödenmiş Sermaye)
Şirket Büyüklük Değerleri	Aktif Toplam	BÜY1	
	Özsermaye (Ana Ortaklık)	BÜY2	
	Net Satışlar	BÜY3	
	Maddi Olmayan Duran Varlıklar	BÜY4	
	Şirket Yaşı	BÜY5	
Temettü Verisi	Hisse Başı Temettü Oranı	HBTOÖ	(Dağıtılan Temettü Miktarı / Net Kâr)
Bağımlı Değişken			
	Piyasa Değeri	PD	(Hisse Senedi Kapanış Fiyatı*Ödenmiş Sermaye)

Bağımsız değişkenler de benzer şekilde ulusal ve uluslararası araştırmalara dayandırılarak oluşturulmuştur. Araştırmanın bağımsız değişkenleri likidite oranları, mali yapı-borçlanma oranları, faaliyet etkinliği oranları, kârlılık oranları, borsa performans oranları, şirket büyüklük değerleri ve temettü verisinden oluşmaktadır. Bu bağımsız değişkenlerin tespitinde literatürde yer alan Omran ve

Ragab (2004), Kalaycı ve Karataş (2005), Özaltın (2006), Weiyng ve Baofeng (2008), Birgili ve Düzer (2010), Chowdhury ve Chowdhury (2010), Gemici (2010), Altan ve Arkan (2011), Büyükşalvarcı ve Uyar (2012), Savsar (2012), Uluyol ve Türk (2013), Küçükkaplan (2013), Pouraghajan vd. (2013), Zor ve Karakuş (2014), Ayriçay ve Türk (2014), Asiri ve Hameed (2014), Kurtaran vd. (2015), Gamayuni (2015), Demirgüneş (2016), Gümüş vd. (2017), Karakaya vd. (2017), Biçen ve Sezgin (2017), Özçalık ve Aytekin (2017), Korkmaz ve Dilmaç (2018), Özdemir ve Öncü (2018), Ege ve Topaloğlu (2018), Husna ve Satria (2019), Akyüz ve Yıldırım (2019), Işıldak (2019), Avcı (2019), Uyar ve Sarak (2020), Avcı (2020) araştırmalarından yararlanılmıştır. Araştırmada her bir değişken için 2011:Q1-2019:Q4 aralığındaki 36 çeyreklik döneme ait veriyi içerdiğinden her bir şirket için veri matrisi 936 (26*36) adet veriden oluşmaktadır. 12 şirket araştırmaya dahil edildiğinden toplam veri deposu da 11.232 (936*12) adetten oluşmaktadır.

Makine öğrenmesi modeller kurulmadan önce veri setinin bazı veri ön işleme ve öznitelik mühendisliği süreçlerinden geçirilmesi gerekmektedir. Bu aşamada, veri ön işleme süreçlerinden kayıp veri analizi ve aykırı verilerin analizi yapılmış iken; öznitelik mühendisliği kapsamında veri setindeki bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin sağlıklı ölçümü anlamında tüm değişkenlerin aynı değer aralığında ifade edilmesi işlemi olan öznitelik ölçeklendirme işlemi gerçekleştirilmiştir.

Veri ön işleme süreci kapsamında kayıp veriler tespit edilmiş ve Seriler Ortalaması (Series Mean) yöntemi kullanılarak tahminleme yapılmıştır. Öznitelik ölçeklendirme kapsamında ise uygulanan normalizasyon (standartlaştırma) işlemi, makine öğrenmesi için veri hazırlama süreçlerinin bir parçasıdır. Normalizasyondaki amaç, veri setinde bulunan sayısal değerleri, değerler aralığındaki farklılıkları bozmadan ortak bir ölçeğe indirgemektir (Dondurmacı ve Çınar, 2014: 262). Farklı yöntemlerle uygulanabilen normalizasyon işlemi, verilerin uygun aralıklarda normalize edilmesiyle yapılan işlemlerin daha hızlı, anlamlı ve kolay yorumlanabilir olduğu tespit edilmiştir (Khemka, 2003: 12-13). Literatürde yer alan ve yaygın kullanılan farklı normalizasyon yöntemleri ise Minimum-Maksimum (Min-Max), Z-skor, Ondalık Ölçeklendirme ve Sigmoid şeklindedir (Jayalakshmi ve Santhakumaran, 2011: 91). Bu araştırmada Min-Max normalizasyon yöntemi uygulanmıştır. Bu yöntemde, dağılım aralığı (0;+1) olacak şekilde standartlaştırma işlemi her bir değerden en küçük değer çıkarılıp, elde edilen değer aralığına bölünmesi ile elde edilir. Bu yaklaşım aykırı değerlerin olduğu durumlarda tercih edilen yaklaşımlardan birisidir (Alpar, 2013: 98).

Ampirik analize yönelik bir ön adım olacak şekilde mevcut veri seti için tanımlayıcı istatistikler olan değişkenlere ait ortalama, standart sapma, minimum, maksimum, çarpıklık, basıklık, Kolmogorov-Smirnov p değerleri Tablo 4'te sunulmuştur. Bu araştırmada Normallik testi için Kolmogorov-Smirnov testinin kullanılmasının nedeni değişkenlere ait gözlem sayısının 29'dan büyük olmasıdır (Kalaycı, 2010:

10). %5 anlamlılık düzeyinde olasılık değerlerinin 0,05'ten küçük olması her bir değişkene ait serinin normal dağılıma uymadığını göstermektedir.

Tablo 4: Veri Setinin Tanımlayıcı İstatistikleri, Normallik Sonuçları

Değişken	Ortalama	Standart Sapma	Minimum	Maksimum	Çarpıklık	Basıklık	Normallik Testi-p değeri
LİK1	1,543	0,746	0,58	5,38	1,501	3,134	0,00
LİK2	1,219	0,76	0,08	4,79	1,686	3,802	0,00
LİK3	0,567	0,612	0,0013	4,394	2,007	5,802	0,00
MALİ1	0,571	0,172	0,14	0,87	-0,195	-0,955	0,00
MALİ2	0,341	0,17	0,06	0,82	0,318	-0,656	0,00
MALİ3	0,367	0,19	0,0002	0,84	0,289	-0,613	0,01
MALİ4	0,378	0,188	0,08	0,81	0,666	-0,533	0,00
FA1	11,777	14,88	0,31	95,23	2,804	8,52	0,00
FA2	154,27	1221,68	0,44	18.846,07	11,827	158,43	0,00
FA3	0,482	0,365	0,01	2,44	1,15	1,687	0,00
FA4	1,08	1,04	0,01	11,71	5,17	44,49	0,00
KAR1	24,67	22,381	-13,27	369,54	9,215	133,423	0,00
KAR2	3,57	17,35	-184,4	41,91	-4,31	37,517	0,00
KAR3	12,718	63,94	-191,7	856,13	7,076	79,551	0,00
KAR4	2,577	6,311	-30,37	38,67	1,005	9,095	0,00
KAR5	8,029	16,923	-57,68	86,16	0,386	3,566	0,00
BOR1	17,264	34,211	0,69	513,09	9,732	118,303	0,00
BOR2	1,056	0,833	0,11	6,84	2,277	7,395	0,00
BOR3	0,606	1,397	-7,69	7,71	0,871	9,404	0,00
BÜY1	34.679.610.000	78.892.550.000	26.893.610	444.008.700.000	3,109	9,63	0,00
BÜY2	5.145.926.571	8.139.599.355	18.637.806	36.282.200.000	2,084	3,313	0,00
BÜY3	3.274.722.176	6.950.467.375	-12.890.000	45.553.400.000	3,177	11,49	0,00
BÜY4	1.464.413.966	3.377.427.608	1.117	23.723.400.000	3,759	16,672	0,00
BÜY5	37,08	13,552	14	69	0,42	-0,507	0,00
HBTOÖ	0,206	0,281	0	2,09	3,76	18,986	0,00
PD	5.593.895.926	9.583.034.269	39.210.000	51.529.500.000	2,424	5,725	0,00

Fisher çarpıklık ve basıklık katsayısı $-/+3$ arasında (bazı yazarlara göre $-/+2$) aralığında ise ilgili değişken normal kabul edilmektedir (Kalaycı, 2010: 209). Aynı şekilde çarpıklık ve basıklık katsayılarına bakılarak da büyük oranda normal dağılıma uyulmadığı şeklinde bir kaniye varılmaktadır.

5. Kurulan Modeller ve Ampirik Bulgular

Makine öğrenmesi algoritmaları yolu ile şirket değeri tahminlemede Python kütüphaneleri olan Pandas, Numpy, Matplotlib, Scikit-learn kullanılmıştır. Scikit-

learn kütüphanesi kullanılarak YSA oluşturmak için MLP Regressor, DVM modeli kurmak için Support Vector Regressor-SVR, KA modeli kurmak için Decision Tree Regressor ve son olarak RO modeli oluşturmak için ise Random Forest Regressor sınıfları kullanılmıştır. Her bir algoritmaya ait aşağıda yer verilen modeller oluştururken veri setine öznitelik ölçeklendirme uygulanarak tahminleme yapılmıştır. Araştırmaya ilişkin yukarıda belirtilen modellerin uygulama süreci şu şekilde yürütülmektedir; gerekli Python kütüphane paketlerinin ve veri setinin çağırılması, öznitelik ölçeklendirme işleminin yapılması, eğitim ve test veri setlerinin %70-%30 şeklinde oluşturulması ile başlamaktadır. Sonrasında ise regresyon sınıflarına ait parametre girişlerinin yapılması ve bu parametre girişleri ile en iyi performansın elde edilmesi amaçlanmaktadır. En iyi performansın göstergesi olarak R^2 'nin yüksek, MAE ve RMSE regresyon performans ölçütlerinin en düşük değer alması amaçlanmaktadır. Fakat bu performans ölçütleri elde edilirken algoritmanın öğrenme süreci sonucunda aşırı öğrenme (overfitting-eğitim veri seti performansının test veri setine göre çok yüksek olması) ve zayıf öğrenme (underfitting-test veri seti performansının eğitim veri setine göre çok daha yüksek olması) durumlarının olmaması istenir. Yani, eğitim veri seti performansı ile test veri seti performansının birbirine yakın olduğu nokta algoritma açısından en iyi performans göstergesi kabul edilmiştir. Eğitim veri seti ile test veri setinin uyum gösterdiği noktada regresyon sınıflarına ait parametreler ve regresyon performans ölçütleri sunulmuştur.

Model-1: YSA Algoritması ile Tahmin Modeli


Tablo 5'te MLP Regressor sınıfı kullanılarak oluşturulan modellere ait performans ölçüm değerleri gösterilmektedir. Bu modelde en iyi performansı gösteren gizli katman sayısı ve maksimum iterasyon değerleri deneme yolu ile bulunmuş olup, diğer parametrelerin default olarak seçilmiştir. Bulgularda test veri seti performansı $R^2=0,9663$; MAE ve RMSE ölçütleri ise sırası ile 0,0286 ve 0,040 olarak tespit edilmiştir. Bağımlı değişkendeki değişimin yüzde kaçının bağımsız değişkenler tarafından açıklanabildiğini konusunda bilgi veren R^2 değeri, 0 ile 1 arasında 0,9663 test performansı göstermiştir. 1'e çok yakın olan bu değer bağımlı değişkendeki değişimin büyük bir bölümünün bağımsız değişkenler tarafından açıklandığını ve varsayımlar sağlandığında modelin uygun olduğunu göstermektedir. Ayrıca, test veri setinde gerçek değerler ile tahmin değerleri arasındaki ilişkiyi kuran MAE ve RMSE ölçüt performanslarının 0'a çok yakın bir değer alması, tahmin performansının yüksekliğine bir işaret etmektedir.

Tablo 5: YSA Modeli Performans Ölçütleri

Gizli Katman Sayısı	Maximum İterasyon Sayısı	Eğitim Performansı (R^2)	Test Performansı (R^2)	MAE	RMSE
40,40,40,40	1000	0,9701	0,9663	0,0286	0,040

YSA modeline ait Tablo 5’te sunulan başarı performansının görselleştirilmiş hali Grafik 1’de sunulmuştur.

Grafik 1: YSA Modeli Gerçek ve Tahmin Edilen Değerlerinin Çizgi Grafiği



Model-2: DVM Algoritması ile Tahmin Modeli


Tablo 6’da DVM modeline ait performans ölçüm değerleri gösterilmektedir. DVM için RBF çekirdeğinin kullanıldığı, en iyi performansı gösteren C değerinin deneme yolu ile bulunduğu ve diğer parametrelerin default olarak seçildiği model sonuçlarına göre C= 124 olduğu parametre noktasında algoritmanın daha önce görmediği test veri seti üzerindeki performansı olan $R^2= 0,900027$ şeklinde tespit edilmiştir. Sırası ile MAE ve RMSE değerleri ise 0,05934 ve 0,06898 olarak tespit edilmiştir. Test veri seti üzerinde R^2 değerinin 0,90 olması, bağımlı değişkenin bağımsız değişkenler tarafından yaklaşık olarak %90’lık bir değerle açıklanabildiğini göstermektedir ki MAE ve RMSE ölçütleri de bu performansı doğrular şekilde 0’a yaklaşmaktadır.

Tablo 6: DVM Modeli Performans Sonuçları

C	Eğitim Performansı (R^2)	Test Performansı (R^2)	MAE	RMSE
124	0,90047	0,90027	0,05934	0,06898

DVM modeline ait Tablo 6’da sunulan başarı performansının görselleştirilmiş hali Grafik 2’de sunulmuştur.

Grafik 2: DVM Modeli Gerçek ve Tahmin Edilen Değerlerinin Çizgi Grafiği



Model-3: KA Algoritması ile Tahmin Modeli

Tablo 7’de Decision Tree Regressor sınıfı kullanılarak oluşturulan modellere ait performans ölçüm değerleri gösterilmektedir. Model parametrelerinden max depth ve min samples leaf parametreleri en iyi performansı elde etmek için deneme yolu


ile tespit edilmiş olup, diğer parametreler ise default olarak seçilmiştir. Test performansı $R^2=0,9400$ olarak tespit edilirken, MAE ve RMSE ölçütleri sırası ile 0,02361 ve 0,053497 şeklindedir. Test veri seti üzerinde R^2 değerinin 0,94 olması, bağımlı değişkenin bağımsız değişkenler tarafından yaklaşık olarak %94'lük bir değerle açıklanabildiğini göstermektedir ki MAE ve RMSE ölçütleri de bu performansı doğrular şekilde 0'a yaklaşmaktadır.

Tablo 7: KA Modeli Performans Sonuçları

Max Depth	Min Leaf Samples	Eğitim Performansı (R^2)	Test Performansı (R^2)	MAE	RMSE
6	16	0,9453	0,9400	0,02361	0,053497

KA modeline ait Tablo 7'de yer verilen başarı performansının görselleştirilmiş hali Grafik 3'te sunulmuştur.

Grafik 3: KA Modeli Gerçek ve Tahmin Edilen Değerlerinin Çizgi Grafığı




Model-4: RO Algoritması ile Tahmin Modeli

Tablo 8'de Random Forest Regressor sınıfı kullanılarak oluşturulan modellere ait performans ölçüm değerleri gösterilmektedir. Model parametrelerinden N estimators ve max depth parametreleri en iyi performansı elde etmek için deneme yolu ile tespit edilmiş olup, diğer parametreler default olarak seçilmiştir. Test performansı $R^2=0,94500$ olarak tespit edilirken, MAE ve RMSE ölçütleri sırası ile 0,029267 ve 0,05123 şeklindedir. Test veri seti üzerinde R^2 değerinin 0,945 olması, bağımlı değişkenin bağımsız değişkenler tarafından yaklaşık olarak %94,5'lik bir değerle açıklanabildiğini göstermektedir ki MAE ve RMSE ölçütleri de bu performansı doğrular şekilde 0'a yaklaşmaktadır.

Tablo 8: RO Modeli Performans Sonuçları

N Estimators	Max Depth	Eğitim Performansı (R^2)	Test Performansı (R^2)	MAE	RMSE
100	2	0,9563227	0,9450011	0,029267	0,0512349

RO modeline ait Tablo 8'de sunulan başarı performansının görselleştirilmiş hali Grafik 4'te sunulmuştur.

Grafik 4: RO Modeli Gerçek ve Tahmin Edilen Değerlerinin Çizgi Grafiği

Modellenen algoritmalar arasında YSA tahmin modeli daha önce görmediği test veri seti üzerinden tahmin performansı $R^2=0.9663$, $MAE=0,0286$ ve $RMSE=0,040$ şeklindedir. Bu bulgulara göre YSA modeli diğer algoritmalara göre en iyi tahmin performansını göstermiştir.

7. Sonuç

Finans yazınının 1950’li yıllar sonrası geldiği teorik süreç, hissedar değerini maksimize edecek varlık ve kaynakların seçimine yönelik kararlar ve bu kararların temel alındığı analitik çalışmalardan oluşmaktadır. Bu dönem ve sonrasında şirket kararlarında değer kaynaklarının belirlenmesi ve şirket değerlendirme çalışmaları odak noktası olmaya devam etmektedir. Değeri yaratan kaynakların belirlenmesinde istatistiksel öğrenme yaklaşımları ile şirket değerlemesinde varlık, piyasa ve gelir bazlı değerlendirme yaklaşımları uygulayıcılar tarafından kullanılırken, yapay zekâ/makine öğrenmesi yaklaşımları temelli algoritmaların değerlendirme alanında kullanımları da yaygınlaşmaktadır.

Gelecekteki fiyatların ve bazı varlıkların değerlerinin ne yönde hareket edecekleri ya da nasıl bir seyir izleyecekleri şirket hissedarları, yatırımcılar ve analistler tarafından geçmişten beri merak uyandırmaktadır. Gelecekteki fiyat ya da değerlerin tahmini için çeşitli istatistiksel, ekonometrik ve yapay zekâ/makine öğrenmesi tabanlı yöntemlerle çeşitli modeller kurgulanmaktadır. Bu çalışmada, Türkiye’de halka açık holding şirketlerinin bilanço ve gelir tablosunda elde edilen ve literatürde kullanımı yaygın şekilde olan finansal oran/verilerden oluşturulmuş bağımlı ve bağımsız değişkenler ile analiz gerçekleştirilmiştir. Bu çerçevede bu çalışmada, Türkiye’de holding şirketlerinin piyasa değerlerini tahmin etmek için bütüncül yapıda tüm değişkenleri içeren makine öğrenmesi algoritmaları temelli YSA, DVM, KA ve RO kullanılarak modeller oluşturulmuş ve model sonuçları karşılaştırmalı sunulmuştur. Analiz sonuçlarına göre YSA algoritmasının test veri seti performansı $R^2=0,9663$, MAE ve RMSE ölçütleri ise sırası ile 0,0286 ve 0,040; DVM algoritmasının test veri seti performansı olan $R^2= 0,900027$, MAE ve RMSE değerleri ise sırası ile 0,05934 ve 0,06898; KA algoritmasının test veri seti performansı $R^2=0,9400$ olarak tespit edilirken, MAE ve RMSE ölçütleri sırası ile 0,02361 ve 0,053497; RO algoritmasının test veri performansı $R^2=0,94500$ olarak tespit edilirken, MAE ve RMSE ölçütleri sırası ile 0,029267 ve 0,05123 olarak

tespit edilmiştir. Dört farklı algoritma arasından YSA modelinin en başarılı performansı ortaya koyduğu tespit edilmiştir.

Bu araştırmada değişkenler arasındaki ilişkilerin ve tahmin işleminin, geleneksel istatistik ve ekonometrik yöntemler dışında, makine öğrenimi algoritmaları aracılığı ile kurgulanmış olması, bu araştırmanın literatüre yapmış olduğu en büyük katkıdır. Bu model kurgularının finansal bilgi kullanıcıları, yatırımcılar, analistler ve şirket hissedarları olarak ifade edilebilecek paydaşlar tarafından daha da geliştirilmesi ve alınacak yatırım kararlarında kullanılması arzu edilen bir durumdur.

Türkiye’de holding şirketleri üzerine yapılan değerlendirme temelli araştırmaların sayısının, diğer sektör endeks gruplarına kıyasla çok kısıtlı olması ve bu yönde bir boşluğun dolduruluyor olması ile literatüre katkı sağlanmaktadır.

Daha sonra yapılması düşünülecek akademik çalışmalar için veri setinin, sürenin ve kapsamın daha da genişletilerek, daha fazla şirket içi ve dışı finansal ya da finansal olmayan parametreler modellere dahil edilerek değer tahminleri kurgulanabilir. Daha farklı makine öğrenmesi, bulanık mantık, veri madenciliği ve derin öğrenme teknikleri ile de değerlendirme alanında tahminleme ve değer yaratan unsurların tespiti yapılabilir, bu alandaki literatür zenginleştirilebilir.

Kaynakça

Açıkkar, M. ve Sivrikaya, O. (2020). Yıkılmış Türk Linyit Kömürlerinin Üst Isıl Değerinin Destek Vektör Regresyonu ile Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (18), 16-24.

Aggarwal, G. ve Singh, L. (2015). Characterization Between Child and Adult Voice Using Machine Learning Algorithm. *International Conference on Computing, Communication and Automation (ICCCA)*, 246-250.

Akar, Ö. ve Güngör, O. (2012). Rastgele Orman Algoritması Kullanılarak Çok Bantlı Görüntülerin Sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 1(2), 139-146.

Akman, M., Genç, Y. ve Ankaralı, H. (2011). Random Forests Yöntemi ve Sağlık Alanında Bir Uygulama. *Türkiye Klinikleri Journal of Biostatistics*, 3(1), 36-48.

Akpınar, H. (2014). *Data Veri Madenciliği Veri Analizi*, İstanbul: Papatya Yayıncılık.

Akyüz, K. C. ve Yıldırım, İ. (2019). Finansal Oranlar ve Firma Değeri İlişkisi: Kağıt ve Kağıt Ürünleri Sanayi Sektöründe Bir Uygulama. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(3), 1778-1792.

Albanis , G. ve Batchelor, R. (2007). Combining Heterogeneous Classifiers for Stock Selection. *Intelligent Systems in Accounting, Finance an Management*, 15, 1-21.

Alpar, R. (2013). *Uygulamalı Çok Değişkenli İstatistiksel Yöntemleri*, Ankara: Detay Yayıncılık.

Altan, M. ve Arkan, F. (2011). Relationship between Firm Value and Financial Structure: A Study on Firms in ISE Industrial Index. *Journal of Business & Economics Research*, 9(9), 61-66.

Asiri, B. K. ve Hameed, S. A. (2014). Financial Ratios and Firm's Value in the Bahrain Bourse. *Research Journal of Finance and Accounting*, 5(7), 1-9.

Atasever, Ü. H. (2011). *Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması* (Yayımlanmamış Yüksek Lisans Tezi). T.C. Erciyes Üniversitesi: Kayseri.

Avcı, P. (2019). *Holding Firmalarında Değer Tespiti ve Borsa İstanbul'da İşlem Gören Holding ile Bağlı Ortaklık ve İştiraklerin Hisse Senedi Fiyatları Arasındaki İlişkinin Analizi* (Yayımlanmamış Doktora Tezi). T.C. Gazi Üniversitesi: Ankara.

Avcı, P. (2020). Firma Piyasa Değeri için Muhasebe ve Ekonomik Verilerin Analizi: Holding Firma Uygulaması. *BMIJ*, 8(4), 387-408.

Ayrıçay, Y. ve Türk, V. E. (2014). Finansal Oranlar ve Firma Değeri İlişkisi: BİST'de Bir Uygulama. *Muhasebe ve Finansman Dergisi*, (64), 53-70.

Aytekin, H. T. (2021). Makine Öğreniminin Araştırmacıların Veri Analizi Bağlamında Potansiyel Önemi. *Ufuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(19), 85-106.

Bıçen, Ö. F. ve Sezgin, H. (2017). Finansal Oranların Firma Değeri Üzerindeki Etkileri: Borsa İstanbul Bilişim Sektörüne Yönelik Bir Panel Veri Analizi. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 15(3), 25-41.

Birgili, E. ve Düzer, M. (2010). Finansal Analizde Kullanılan Oranlar ve Firma Değeri İlişkisi: İMKB'de Bir Uygulama. *Muhasebe ve Finansman Dergisi*, (46), 74-83.

Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5-32.

Büyükşalvarcı, A. ve Uyar, S. (2012). Farklı Muhasebe Düzenlemelerine Göre Hazırlanan Mali Tablolardan Elde Edilen Finansal Oranlar ile Şirketlerin Hisse Senedi Getirileri ve Piyasa Değerleri Arasındaki İlişki. *Muhasebe ve Finansman Dergisi*, (53), 25-48.

Chong, Z., Xinrui, Z. ve Zipei, Y. (2020). Enterprise Investment Value Analysis Based on Machine Learning Model of Rapidminer. *Journal of Physics: Conference Series*. DMCIT 2020 IOP Publishing.

Chowdhury, A. ve Chowdhury, S. P. (2010). Impact of Capital Structure on Firm's Value: Evidence from Bangladesh. *Business and Economic Horizons*, 3(3), 111-122.

Çayıroğlu, İ. (2015). *Görüntü İşleme 11. Hafta-Yapay Sinir Ağları*. http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-11.Hafta.pdf, (Erişim: 26.04.2022)

Çomak, E. (2008). *Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar* (Yayımlanmamış Doktora Tezi). T.C. Selçuk Üniversitesi: Konya.

Damodaran, A. (2006). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*, New Jersey: John Wiley & Sons.

Damodaran, A. (2011). *The Little Book of Valuation: How to Value a Company, Pick a Stock, and Profit*, New Jersey: John Wiley & Sons.

Demirgüneş, K. (2016). Firma Değerinin Finansal Belirleyicileri: Ampirik Bir Analiz. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(1), 159-179.

Detienne, K. B., Detienne, D. H. ve Joshi, S. A. (2003). Neural Networks as Statistical Tools for Business Researchers. *Organizational Research Methods*, 6(2), 236-265.

Dondurmacı, G. A. ve Çınar, A. (2014). Finans Sektöründe Veri Madenciliği Uygulaması. *Akademik Sosyal Araştırmalar Dergisi*, 2(1), 258-271.

Eakins, S. G. ve Stansell, S. R. (2003). Can Value-Based Stock Selection Criteria Yield Superior Risk-Adjusted Returns: An Application of Neural Networks. *International Review of Financial Analysis*, 12(1), 83-97.

Ege, İ. ve Topaloğlu, T. N. (2018). Piyasa Değerinin Firmaya Özgü Belirleyicileri: BİST 30 Firmaları Üzerine Panel Veri Analizi. *Kırşehir Ahi Evran Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 2(1), 110-129.

Ekşi, İ. H., Çakır, V., Büyükkonuklu, B. ve Özçalıcı, M. (2014). Prediction of Firm Value with Financial Structure Items: An Implementation on Metal Industry. *Journal of Financial and Actuarial Mathematics and Management*, 2, 1-10.

Er, F. (2020). *Gayrimenkul Değerlemesinde Makine Öğrenmesi Tekniklerinin Kıyaslanması* (Yayımlanmamış Yüksek Lisans Tezi). T.C. Yıldız Teknik Üniversitesi: İstanbul.

Ercan, M. K., Öztürk, M. B., Küçük Kaplan, İ., Başcı, E. S. ve Demirgüneş, K. (2006). *Firma Değerlemesi Banka Uygulaması*, İstanbul: Literatür Yayıncılık.

Ertuğrul, M. (2008). Değer-Fiyat Ayrımı ve İşletme Değeri: Kuramsal Bir Bakış. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(2), 143-154.

Gamayuni, R. R. (2015). The Effect of Intangible Asset, Financial Performance and Financial Policies on The Firm Value. *International Journal of Scientific & Technology Research*, 4(1), 202-212.

Gemici, Ç. G. (2010). *Mali Oranların Firma Değerine Etkisinin Analizi* (Yayımlanmamış Yüksek Lisans Tezi). T.C. Ankara Üniversitesi: Ankara.

Gümüş, U. T., Şakar, Z., Akkın, G. ve Şahin, M. (2017). Finansal Analizde Kullanılan Oranlar ve Firma Değer İlişkisi: BİST’de İşlem Gören Çimento Firmaları Üzerine Bir Analiz. *Karadeniz Sosyal Bilimler Dergisi*, 9(16), 1-23.

Gürbüz, A. O. ve Ergincan, Y. (2008). *Şirket Değerlemesi Klasik ve Modern Yaklaşımlar*, İstanbul: Literatür Yayınları.

Hamel, L. H. (2009). *Knowledge Discovery with Support Vector Machine*, New Jersey: Wiley-Interscience.

Han, J., Kamber, M. ve Pei, J. (2012). *Data Mining Concept and Techniques*, Amsterdam: Elsevier.

Hitchner, J. R. (2006). *Financial Valuation: Applications and Models*, New Jersey: John Wiley & Sons.

Hood, H. L. ve Lee, T. R. (2011). *A Reviewer's Handbook to Business Valuation*, New York: John Wiley & Sons.

Hsiao, K., Li, J. B. ve Chen, A. P. (2006). Improving Investing Strategy in Stock Market with Valuation. *International Journal of Computational Intelligence Research*, 2(1), 26-32.

Husna, A. ve Satria, I. (2019). Effects of Return on Asset, Debt to Asset Ratio, Current Ratio, Firm Size, and Dividend Payout Ratio on Firm Value. *International Journal of Economics and Financial Issues*, 9(5), 50-54.

Işıldak, M. S. (2019). Finansal Oranların Piyasa Değeri/Defter Değeri Oranına Etkisinin Panel Veri Analiziyle İncelenmesi: BİST’te Kayıtlı Dokuma, Giyim Eşyası ve Deri Sektöründe Uygulama. *Ekonomik Yaklaşım*, 30(111), 71-100.

İvgen, H. (2003). *Şirket Değerleme*, İstanbul: Finnet Yayıncılık.

Jayalakshmi, T. ve Santhakumaran, A. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 3(1), 89-93.

Kaderli, Y. ve Küçükkaya, H. (2012). 2008 Dünya Finansal Krizi Sonrası Türkiye Ekonomisinde Yaşanan Gelişmelerin Bazı Ülkelerle Karşılaştırmalı Olarak İncelenmesi. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12, 85-96.

Kalaycı, Ş. (2010). *SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri*, Ankara: Asil Yayın Dağıtım.

Kalaycı, Ş. ve Karataş, A. (2005). Hisse Senedi Getirileri ve Finansal Oranlar: İMKB'de Bir Temel Analiz Araştırması. *Muhasebe ve Finansman Dergisi*, (27), 146-157.

Kantardzic, M. (2001). *Data Mining: Concepts, Models, Methods, and Algorithms*, New York: John Wiley & Sons.

Karakaya, A., Turan Kurtaran, A. ve Kurtaran, A. (2017). Firm Value and External Financing Needs. *International Journal of Economics and Finance*, 9(6), 69-81.

Kaya, D. G. ve Kaygısız, A. D. (2015). 2008 Küresel Finans Krizi ve Sonrasında Türkiye'de Uygulanan Maliye Politikalarına Genel Bir Bakış. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 11(26), 171-194.

Khemka, A. (2003). A Collaborative Predictive Data Mining Model. *A Collaborative Predictive Data Mining Model*. Missouri: Faculty of University of Missouri-Kansas City.

Korkmaz, Ö. ve Dilmaç, M. (2018). Firma Piyasa Değerini Etkileyen Finansal Faktörler: Banka ve Sigorta İşletmeleri Üzerine Bir Uygulama. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 16(2), 179-201.

Kryzanowski, L., Galler, M. ve Wright, D. W. (1993). Using Artificial Neural Networks to Pick Stocks. *Financial Analysts Journal*, 49(4), 21-27.

Kurtaran, A., Turan Kurtaran, A., Kurtaran Çelik, M. ve Temizer, Z. (2015). Finansal Oranlar ile Firma Değeri İlişkisi: BIST'te Bir Uygulama. *Küresel İktisat ve İşletme Çalışmaları Dergisi*, 4(8), 35-45.

Kuzey, C., Uyar, A. ve Delen, D. (2014). The Impact of Multinationality on Firm Value: A Comparative Analysis of Machine Learning Techniques. *Decision Support Systems*, 59, 127-142.

Küçük Kaplan, İ. (2013). İstanbul Menkul Kıymetler Borsasında İşlem Gören Üretim Firmalarının Piyasa Değerini Açıklayan İçsel Değişkenler: Panel Verilerle Sektörel Bir Analiz. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 8(2), 161-182.

Lee, J. ve Kwon, H. B. (2017). Progressive Performance Modeling for the Strategic Determinants of Market Value in the High-tech Oriented SMEs. *International Journal of Production Economics*, 183, 91-102.

Metlek, S. ve Kayaalp, K. (2020). *Makine Öğrenmesinde, Teoriden Örnek Matlab Uygulamalarına Kadar Destek Vektör Makineleri*, Ankara: İKSAD Yayınevi.

Milosevic, N. (2016). Equity forecast: Predicting long term stock price movement using machine learning. *arXiv 2016*. arXiv:1603.00751 adresinden alındı.

Olson, D. L. ve Delen, D. (2008). *Advanced Data Mining Techniques*, Berlin: Springer.

Olson, D. ve Mossman, C. (2003). Neural Network Forecasts of Canadian Stock Returns Using Accounting Ratios. *International Journal of Forecasting*, 19(3), 453-465.

Omran, M. ve Ragab, A. (2004). Linear Versus Non-linear Relationships Between Financial Ratios and Stock Returns: Empirical Evidence from Egyptian Firms. *Review of Accounting and Finance*, 3(2), 84-102.

Özaltın, O. (2006). *Sermaye Yapısı ve Firma Değeri İlişkisi İMKB'de Bir Uygulama (2000-2003)* (Yayımlanmamış Yüksek Lisans Tezi). T.C. Süleyman Demirel Üniversitesi: Isparta.

Özçalık, S. G. ve Aytekin, S. (2017). İşletme Değeri ile Finansal Oranlar Arasında İlişki Var mı? Borsa İstanbul'da Bir Uygulama. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 20(38), 203-214.

Özdemir, Ö. ve Öncü, E. (2018). Muhasebe Verilerinin Firma Değerine Etkisi: Borsa İstanbul Metal Sektörü Üzerine Bir Uygulama. *Muhasebe ve Finansman Dergisi*, (78), 125-138.

Özdemir, Ş. (2017). Karar Ağaçları. U. Çelik, E. Akçetin, ve M. Gök (Ed.) içinde, *Rapidminer ile Uygulamalı Veri Madenciliği* (s. 107-1028). İstanbul: Pusula 20 Teknoloji ve Yayıncılık A.Ş.

Özkan, Y. (2013). *Veri Madenciliği Yöntemleri*, İstanbul: Papatya Yayıncılık.

Öztemel, E. (2006). *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık.

Öztürk, H. (2009). *Şirket Değerlemesinin Esasları Teorik ve Pratik Yaklaşımlar*, İstanbul: Türkmen Kitabevi.

Pal, M. (2005). Random Forest Classifier For Remote Sensing Classification. *International Journal of Remote Sensing*, 26(1), 217-222.

Pao, H.-T., Yu, C.-H. ve Fu, H.-C. (2020). Corporate Value Prediction Model and Sensitivity Analysis of Taiwan Traditional Industry Based on Machine Learning Algorithm. I. S. International (Dü.). içinde *Dubai: Proceedings of the International Conference on Industrial Engineering and Operations Management*.

Peştere, M. (2021). *Değere Dayalı Derecelendirme: Makine Öğrenmesi Yöntemleri ile Bir Sinama* (Yayımlanmamış Yüksek Lisans Tezi). T.C. Pamukkale Üniversitesi: Denizli.

Pouraghajan, A., Mansourinia, E., Bagheri, B., Emamgholipour, M. ve Emamgholipour, B. (2013). Investigation the Effect of Financial Ratios, Operating Cash Flows and Firm Size on Earnings Per Share: Evidence from the Tehran Stock Exchange. *International Research Journal of Applied and Basic Sciences*, 4(5), 1026-1033.

Savsar, A. (2012). *Finansal Oranlarla Firma Deęeri Arasındaki İliŐki ve İstanbul Menkul Kıymetler Borsası'nda Bir Uygulama* (YayımlanmamıŐ Yüksek Lisans Tezi). T.C. GaziosmanpaŐa Üniversitesi: Tokat.

Seyidođlu, H. (1992). *Ekonomik Terimler Ansiklopedik Sözlük*, Ankara: Güzem Can Yayınları.

Shwartz, S. S. ve David, S. B. (2014). *Understanding Machine Learning: From Theory to Algorithms*, New York: Cambridge University Press.

Uđuz, S. (2021). *Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zeka Ekolü*, Ankara: Nobel Akademik Yayıncılık.

Uluyol, O. ve Türk, V. E. (2013). Finansal Rasyoların Firma Deęerine Etkisi: Borsa İstanbul (BİST)'da Bir Uygulama. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(2), 365-384.

Uyar, U. ve Sarak, G. (2020). Finansal Oranlar ile Firma Deęeri İliŐkisinin Borsa İstanbul ve Londra Borsası İmalat Sanayi Sektörlerinde KarŐılaŐtırılması. *Ekonomi, Politika ve Finans AraŐtırmaları Dergisi*, 5(3), 537-560.

Vercellis, C. (2009). *Business Intelligence: Data Mining and Optimization for Decision*, New York: Wiley.

Weiyang, J. ve Baofeng, C. (2008). Financial Risk, Business Risk and Firm Value for Logistics Industry. *4th International Conference on Wireless Communications Networking and Mobile Computing*, 1-4.

Wilimowska, Z. ve KrzysztoŐek, T. (2013). The Use of Artificial Neural Networks in Company Valuation Process. *Studies in Computational Intelligence*, 279-288.

Witten, I. H., Frank, E. ve Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*, USA: Morgan Kaufman Publications.

Yakut, E. (2012). *Veri Madencilięi Tekniklerinden C5.0 Algortiması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının KarŐılaŐtırılması: İmalat Sektöründe Bir Uygulama* (YayımlanmamıŐ Doktora Tezi). T.C. Atatürk Üniversitesi: Erzurum.

Zakaria, M., Al-Shebany, M. ve Sarhan, S. (2014). Artificial Neural Network: A Brief Overview. *Int. Journal of Engineering Research and Applications*, 4(2), 7-12.

Zhang, C., Zhang, H. ve Liu, D. (2016). Energy Firm Value Prediction Using Machine Learning. *IEEE Access*, 4, 1-9.

Zocca, V., Spacagna, G., Slater, D. ve Roelants, P. (2017). *Python Deep Learning*, Birmingham: Packt Publishing.

Zor, İ. ve Karakuş, R. (2014). Tek Düzen Hesap Planı ve UFRS'ye Göre Elde Edilen Finansal Oranların Hisse Getirileri İle İlişkisinin Karşılaştırmalı İncelenmesi: BİST'te Bir Uygulama. *Yaşar Üniversitesi E-Dergisi*, 9(34), 5870-5886.

<https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir>, (Erişim: 06.04.2022).