



MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE SERMAYE YAPISININ BELİRLENMESİ; BİST’TE UYGULAMA

Şafak Sönmez SOYDAŞ¹

Öz

Bu çalışma, firmaların fonlama kararlarını önemli ölçüde etkileyen firmaya özgü faktörleri belirlemek ve geliştirmek için makine öğrenmesi yöntemlerine dayalı bir model oluşturmak amacıyla gerçekleştirilmiştir. Çalışma, 2014-2023 yılları arasında Borsa İstanbul’da orman, kâğıt ve basım endeksinde sıralanan firmalardan oluşmakta olup makine öğrenmesi yöntemleri ile sermaye yapısı kararları analiz edilmiştir. Makine öğrenmesi yöntemleri kullanılarak yapılan analizler sonucunda oluşturulan modeller içerisinde özellikle XGBoost yöntemi ile oluşturulan model ve Random Forest modelinin performans değerlerinin AdaBoost ve SVM modeline göre daha iyi performans gösterdiği tespit edilmiştir. Özellikle XGBoost ve Random Forest yöntemi ile oluşturulan modellerin kurumsal sermaye yapılarının belirlenmesi için daha iyi bir seçenek olduğu görülmüştür. En kötü performansın ise SVM modeli olduğu anlaşılmıştır.

Anahtar Kelimeler: Sermaye Yapısı, Finansal Oran, Makine Öğrenmesi
JEL Sınıflandırması: B23, G17, G32

MACHINE LEARNING METHODS IN CAPITAL STRUCTURE DECISIONS; APPLICATION IN BIST

Abstract

This study was conducted to create a model based on machine learning methods to determine and develop firm-specific factors that significantly affect the funding decisions of firms. The study consists of firms listed in the forest, paper and printing index of Borsa İstanbul between 2014-2023, and their capital structure decisions were analyzed with machine learning methods. As a result of the analyzes made using machine learning methods, it was determined that the performance values of the model created with the XGBoost method and the Random Forest model, in particular, performed better than the AdaBoost and SVM models. It was seen that the models created with the XGBoost and Random Forest methods were a better option for determining corporate capital structures. It was understood that the SVM model had the worst performance value.

Keywords: Capital Structure, Financial Ratio, Machine Learning
JEL Classification: B23, G17, G32

¹ Dr., Gümüşhane Üniversitesi, İrfan Can KÖSE MYO, Mülkiyet Koruma ve Güvenlik Bölümü, e-posta: safaksoydas@gumushane.edu.tr,
ORCID iD: <https://orcid.org/my-orcid?orcid=0000-0002-7174-8652>

1. GİRİŞ

Bir firmanın ihtiyaç duyduğu fonların finansmanında kullandığı vadesi bir yıldan az olan kaynakların devamlılık arz eden kısmı, vadesi bir yıldan fazla olan kaynakların ve özsermayenin beraber oluşturulduğu yapı sermaye yapısı olarak ifade edilmektedir. Bir başka deyişle sermaye yapısı, bir firmanın ana faaliyetlerinde kullanacağı kaynakları finanse etmede kullandığı menkul kıymetlerin (uzun vadeli borçlar, adi hisse senetleri, imtiyazlı hisse senetleri vb. gibi) bir arada kullanılmasıdır (Qian, Tian ve Wirjanto, 2007). Sermaye yapısının bileşiminde borçlanma ya da özsermaye yöntemlerinden hangisinin kullanılıp varlıkların fonlandığı konusu önem arz etmektedir. Bu fonların kullanımında çoğunlukla özsermaye kullanmanın maliyeti, dış kaynak kullanmanın maliyetinden yüksek olmaktadır (Terim ve Kayalı, 2009).

Firmaların aldıkları finansal kararlar ve belirledikleri politikalar kendi organizasyon kültürü için önemli bir rol oynamaktadır. Sermaye yapısı, bir firmanın varlıklarını finanse etmek için kullanılan fonların yapısını ifade eder. Ayrıca bir firmanın sermaye yapısı, organizasyon içinde karar alma sürecindeki birçok etkenin birleşimi ile şekillenmektedir.

Modigliani ve Miller (1958) 'ın, sermaye yapısının önemi hakkında öne sürdüğü fikirler hala tartışmalı olmasına rağmen kabul edilen bir olgudur. Bu tartışmanın temelinde piyasa sürüşmelerinde sermaye yapısının önemli bir konu olduğunu kabul edilmektedir (Modigliani ve Miller, 1963:433-443). Yaklaşık bir asra yakın zaman diliminde, sermaye yapısı kararlarının altında yatan kesin nedenler hâlâ tam olarak açıklanamamıştır (Graham, Leary ve Roberts, 2015:658-683).

Sermaye yapısı teorileri, bir işletmenin optimal sermaye yapısını belirlemeye çalışır ve hangi faktörlerin sermaye kararlarını etkilediğini açıklar. Firmaların sermaye yapısı tercihlerini açıklayan çeşitli teoriler önerilmiştir. Bu teoriler klasik teoriler ve modern teoriler olarak iki kısımda değerlendirilmektedir. Klasik teoriler sınıflandırmasında Modigliani-Miller teorisi (M&M) ve Trade-Off Teorisi (Takas teorisi), modern sermaye yapısı teorileri ise, Pecking Order Teorisi (Öncelik sırası teorisi), Ajans Teorisi (vekalet teorisi), Sinyal Teorisi ve Denge Teorisi şeklinde değerlendirilmektedir.

• Modigliani-Miller Teorisi (M&M)

Bu teori etkin bir piyasa varsayımında vergi etkisinin olmadığı durumlarda sermaye yapısının firma değeri üzerinde bir etkisinin olmadığını savunmaktadır (Modigliani ve Miller, 1958). Modigliani ve Miller (1963), çalışmalarında daha önceki teorilerine vergi faktörünü de dahil ederek teoriyi genişlettiler. Bu teoriye göre, vergi ilave edildiğinde firmaların dış kaynak kullanımı ile vergi avantajı ortaya çıkacağı ve bu avantaj ile firmanın değerinin artabileceği ifade edilmektedir. Kullanılan yabancı kaynaktan dolayı ödenen faiz giderleri, vergi matrahından azaltılacağı için firmalar bu durumu vergi avantajı olarak kullanabileceklerdir. Sonuç olarak bu teori ile sermaye maliyeti ve firma değeri arasındaki ilişki analiz edilmektedir (Modigliani ve Miller, 1963:433-443).

• Takas Teorisi

Bu teori dış kaynak kullanımının oluşturacağı vergi avantajları ile iflas maliyetleri arasındaki dengeyi oluşturarak en uygun sermaye yapısının belirlenebileceğini savunmaktadır. Ayrıca vergi avantajının bir noktaya kadar borçlanmayı tetiklediği, ancak dış kaynak kullanım oranı yükseldikçe iflas maliyetlerinin de ortaya çıkacağını öne sürmektedir. Bu teori, optimal sermaye yapısı oluşumunu ifade etmek için geniş kapsamlı bir çerçeve sunmaktadır. Fakat bilgi asimetrisi, ajans maliyetleri gibi reel ekonomik kriterleri bir bütün olarak değerlendirmede için bazı kısıtlamaları bulunmaktadır (Kraus ve Litzenberger, 1973; Myers, 1984).

• Hiyerarşi Teorisi

Bu teori, firmalar sermaye yapısını oluştururken alınacak borçlanma kararlarını belirlemek için kaynak sıralamasını firmanın finansal durumuna göre belirlenen öncelik sırasına göre kararlar aldığını ve alınan kararların bilgi asimetrisinden dolayı oluştuğunu savunmaktadır. Yani temelde firmanın kullanacağı kaynaklarının firma içinden mi yoksa dışından mı karşılanacağı konusu üzerine tercih sırasını belirtmektedir. Maliyetleri azaltmak, iç kaynak finansman faydası, kullanılan borcun vergi yönünden faydası gibi avantajları bulunmakta iken yönetici ve pay sahipleri arası çatışmalar, piyasa koşullarındaki dalgalanmalar ve bunun sonucunda sıralamaların değişmesi ve firmaların karlılık oranlarındaki farklılıklar olması nedeniyle bu teorelin sınırlılıkları söz konusu olmaktadır (Myers ve Majluf, 1984; Leland ve Pyle, 1977; Bontempi, 2002).

• Vekalet Teorisi

Bu teori, firmaları idare edenler ve firma ortakları arasında menfaat sirtüşmesi olduğunu ve bu durumun da alınacak finansman kararında etkin bir şekilde faydalanılacağı yönünde görüşlerden oluşmaktadır. Kaynak kullanımının, firmaları idare edenler üzerinde düzenleyici etki unsuru oluşturmaları onları pay sahiplerinin menfaatleri lehine eylemlerde bulunmaya iteceğini ifade etmektedirler. Ayrıca özsermaye maliyetinin borç-özsermaye oranıyla doğrusal bir şekilde arttığını açıklamaktadır. Çünkü artan finansal kaldıracın sistematik riski yükselttiği varsayılır. Sermayenin ağırlıklı ortalama maliyeti sabit kaldığında borç-özsermaye oranından bağımsız olur. Yani artan özkaynak maliyeti, daha ucuz borç finansmanının artan payı ile dengelenmektedir. Bunun yanı sıra bu teori ajans giderlerini kısmak için çeşitli öneriler belirtse de bir takım bazı sınırlamalar söz konusudur. Bunlar ise yüksek dış kaynak kullanımının firmaları finansal sıkıntıya sokma ihtimali, firmaları idare edenler ve firma ortakları arasındaki sirtüşmenin tam olarak giderilememesi ve dış çevre faktörlerinde toplumsal sorumluluk gibi konuların kapsam dışında tutulması gibi sınırlamalardır (Jensen ve Meckling, 1976; Harris ve Raviv, 1991).

• Sinyal Teorisi

Bu teori, firmalar hakkında oluşan tüm gelişmelerin olumlu ya da olumsuz bir işaret olarak anlaşılması gerektiğini savunmaktadır. Bundan dolayı bilginin maliyetsiz bir şekilde firma paydaşlarına aktarılması sağlanmaktadır. Firmalar dış kaynak kullanarak ya da pay senedi üretmek firmaya yatırım yapanlara kendi sermaye yapısı hususunda ayrıntılı bilgi vermektedir. Dış kaynak kullanımı pozitif bir sinyal olarak değerlendirilirken pay senedi ihraçları genellikle negatif olarak değerlendirilmektedir. Bu teori, alınan finansal kararların sadece finansal bir karar olmadığını aynı zamanda oluşan bilgileri idare etme vasıtası olduğunu ifade etmektedir (Ross, 1977; Leland ve Pyle, 1977).

• Dengeleme Teorisi

Bu teoreli ise en uygun borç düzeyinde firmaların sermaye yapıları belirlenirken kullanılan borcun iflas maliyeti ve borçlanmanın sağladığı fırsatları dengeleyerek en uygun sermaye yapısını sağlamak için öne sürülmüştür (Kraus ve Litzenberger, 1973). En uygun finansal karar alma mekanizması, verginin sağladığı gelir avantajlarının finansal sıkıntı giderlerini telafi edecek düzeyde olduğu borç-özkaynak karışımı olarak ifade edilmektedir. Bundan dolayı dengeleme teoreli, dış kaynak kullanmanın sağladığı artıları en üst aşamaya yükseltmeyi planlarken iflasın oluşturduğu olumsuzlukları asgari seviyeye indirmeyi hedeflemektedir. Fakat bu teori, firma idarecileri ve yatırım yapanların aynı bilgi düzeyinde olmaması, piyasa koşullarında dalgalanmaların olması ve yatırımcıların karşılaştığı menfaat karmaşası, bilgi asimetrisi ve ajans maliyetlerini göz ardı etmesi ve büyüme olanaklarını göz ardı etmesi nedenlerinden dolayı bazı kısıtlamalar söz konusudur (Myers, 1984; Jensen, 1986).

Sermaye yapısı ile ilgili önceki çalışmalara bakıldığında, bir firmanın sermaye yapısının belirlenmesinde yalnızca firmaya özgü faktörlerin olmadığı, aynı zamanda ülkeye özgü faktörlerden de etkili olduğu görülmektedir (De Jong, Kabir ve Nguyen, 2008:1954-1969). Tek bir ülkedeki firmalar üzerine yapılan çalışmalar, çoğunlukla o ülkedeki firmalar arasındaki sermaye yapısında oluşan farklılıkları ifade etmek için firmaya has etmenleri kullanmaktadır. Eğer küresel temelde araştırma yapılmış ise, sermaye yapısındaki farklılıkları ifade etmek için hem firmaya hem de ülkeye özgü etmenleri kullanarak, farklı ülkelerdeki firmaların sermaye yapısı seçimindeki farklılıkları karşılaştırmak gerekir. Sonuç olarak, sermaye yapısının belirlenmesinde hem firmaya hem de ülkeye özgü faktörlerin önemli açıklayıcı güce sahip olduğu görüşü savunulmaktadır (Li ve Islam, 2019: 425-437).

Sermaye yapısı kararlarında yapılan çalışmalar genellikle geleneksel istatistiksel yöntemler ve basit regresyon modelleri şeklindedir. Bu yöntemler, belirli değişkenler arasındaki ilişkileri analiz etmek ve gelecekteki olayları tahmin etmek için kullanılmıştır. Ancak, sermaye piyasası kararlarında bu yaklaşımların bazı sınırlamaları bulunmaktadır. Bunlar, finansal piyasalar genellikle karmaşık ve dinamik yapıya sahip olduğundan basit regresyon modelleri ve geleneksel istatistiksel yöntemler, bu karmaşıklığı yeterince yönetmekte zorlanabilmektedir. Ayrıca geleneksel yöntemler genellikle büyük veri kümelerini etkili bir şekilde işleyemez. Sermaye piyasalarında artan miktarda veri bulunmaktadır ve bu verilerin etkili bir şekilde işlenmesi ve analiz edilmesi önemlidir. Makine öğrenmesi, karmaşık yapıları daha iyi yönetebilir ve finansal piyasalardaki çeşitli faktörler arasındaki etkileşimleri daha iyi anlayabilir. Bu etkenlerden dolayı firmaların fonlama kararlarını önemli ölçüde etkileyen firmaya özgü faktörleri belirlemek ve geliştirmek için makine öğrenme veri setine dayalı bir model oluşturmak amaçlanmıştır.

Yapılan bu çalışmada, 2014-2023 yılları arasında Borsa İstanbul’da orman, kâğıt ve basım endeksinde sıralanan 15 firma içinden bahse konu yıllar arasında, Kamuoyu Aydınlatma Platformu (KAP)’undan ulaşılan 9 firmaya ait veriler çalışılmıştır. Bu sektörün tercih edilmesinin temel nedenleri ise imalat sektöründe bulunması ve sektörde makine öğrenmesi yöntemleri ile çalışma yapılmamış olması, daha önce bu tür firmaların sermaye yapıları belirleyicileri üzerine bir çalışmanın olmamasından kaynaklanmaktadır. Çalışmanın, makine öğrenmesi tekniklerinin sermaye piyasası analizine yeni bir bakış açısı sağlaması anlamında literatüre katkıda bulunacağı düşünülmektedir. Literatürdeki bilgiyi genişletmek, eksiklikleri gidermek ve gelecekteki araştırmalar için bir temel oluşturmak açısından önemli bir rol oynaması beklenmektedir. Ayrıca, makine öğrenmesinin sermaye piyasası kararlarının analizindeki kullanımının avantajlarını göstermek ve bu alandaki araştırmacıların ve profesyonellerin dikkatini çekmek amaçlanmıştır. Çalışmayı diğer çalışmalardan ayıran özelliği, farklı bir sektörde sermaye yapısı kararları için ilk kez makine öğrenme yöntemleri kullanılmış ve sermaye yapısı kararlarında bu yöntemlerin kullanılabileceği ve bu yönüyle literatüre katkı sağlayacağı düşünülmektedir. Çalışmanın diğer bölümlerinde literatür taraması, metodoloji ve çalışmanın sonuçları özetlenmiştir. Son bölümde ise araştırma sonuçlarının yorumlanmasına yer verilmiştir.

2. LİTERATÜR TARAMASI

Yazında birçok ampirik çalışmanın büyüklük ve kârlılık gibi sermaye yapısının bir dizi kesitsel belirleyicisi üzerine yapıldığı görülmektedir (Lemmon, Roberts ve Zender, 2008; Dang, Kim ve Shin, 2012). Bu çalışmalarda, kaldıraç ve kârlılık arasındaki negatif ilişkinin olduğu özellikle vurgulanmaktadır. Sermaye yapısı üzerine yapılan çalışmalarda kârlılık-kaldıraç ilişkisindeki doğrusal olmayan bir yapının olduğu ve bu durumun araştırılması gereken bir konu olduğu öne sürülmektedir (Katagiri, 2014:80).

Bir şirketin finansman tercihi üzerinde önemli etkisi olan bazı temel iç faktörler bulunmaktadır. Bu faktörlerin, şirket karlılığı, büyüklüğü, büyüme fırsatları, vergi dışı koruma ve varlık durumu olduğu öne sürülmüştür (Bauer, 2004; Bokpin, 2009; Frank and Goyal, 2009; Kouki and Said, 2012; Nguyen and Wu, 2011).

Booth, Aivazian, Demircuc-Kunt ve Maksimovic (2001), farklı kurumsal yapıya sahip ülkelerde sermaye yapısı teorilerinin değiştirilebilir olup olmadığını test etmek için 10 farklı gelişmekte olan ülkelerin gelişmiş ülkelerdeki gibi sermaye yapısı tercihlerinin benzer olduğu kanısına varmıştır.

Löf (2003), farklı firma büyüklüğü ve farklı ülkelerdeki firmaların kurumsal sermaye yapılarını etkileyen değişkenleri incelemiştir. Bulgular ülkelerde bulunan firmaların birbirinden bağımsız ekonomik şartlarda ve büyüklükte olsalar bile sermaye yapılarını belirleyen faktörlerin farklı olmayacağı sonucuna varmıştır.

Ulusoy (2008), finansal oranları kullanarak borsada işlem gören 30 firmanın finansal yapılarını ve sistematik riskini belirlemiştir. Çalışma sonucunda firmaların finansal oranları ile betaları arasında anlamlı bir ilişkinin olmadığı, ek olarak oranlar beta katsayısı arasında korelasyonun varlığı modelin anlamlılık seviyesini pozitif veya negatif olarak etkileyebileceğini ifade etmiştir.

Sufi (2009), sermaye yapısındaki artışın sermaye üzerinde ne gibi artışlar olduğunu incelemiştir. Firma özelliğinin karakteristik yapısı ve sermaye artış şartlarının kurumsal temelde borç kullanımı üzerinde önemli bir etkiye sahip olduğunu bulmuştur.

Terim ve Kayalı (2009), Aynı sektörde faaliyet gösteren firmaların sermaye yapısı belirleyicilerini, karlılık, net sabit varlıklar, büyüme fırsatları ve sermaye yapıları faktörlerinde incelemiş ve anlamlı ilişki tespit etmiştir.

Lemmon, Michael, Roberts ve Zender (2008), firmaların sermaye yapısı kararlarında firma büyüklüğü, varlık yapısı ve sermaye yapısı belirleyicileri üzerinden değerlendirmiştir. Karlılığın sermaye yapısını olumlu etkilediği fakat diğer değişkenlerin sermaye yapısını olumsuz etkilediği sonucuna varmıştır.

Sheikh ve Wang (2011) ve Anwar (2012), borsa şirketleri üzerinde sermaye yapısı kararlarını etkileyen etmenleri incelemişler. Finansal hiyerarşi kuramı ile firmalar sermaye yapılarını belirlediklerini ve karlılık, likidite ve borç oranlarının negatif ilişki içinde oldukları kanısına ulaşmıştır.

Pratheepkanth (2011), borsa dışı firmaların sermaye yapılarını incelemiş, bu firmaların sermayelerinin genellikle öz sermayeden oluştuğunu ve öz sermaye ve karlılık arasında ilişkinin negatif ve anlamlı olduğunu açıklamıştır.

Graham ve Leary (2011), firma idarecilerinin alınan finansal kararlar için firma içi, firma dışı ve sektörler arası boyutta değerlendirmiş geleneksel yaklaşım ile yapılan çalışmaların bu borç yapısını hangi ölçüde açıkladığını özetlemiş ve var olan eksikliklere dikkat çekmiştir.

Dang, Kim ve Shin (2012), dinamik panel eşik modeli ile dengeleme teorisini borçlanma hedeflerine doğru asimetrik ve borçlanma maliyetlerinin ayarlamasına olanak tanıyan, dinamik takas teorisini analiz etmek için yeni bir yaklaşım oluşturmayı amaçlamıştır. Büyük finansman açığı, büyük yatırımların olası volatilitesi veya düşük kazanç volatilitesi olan firmaların karşıt özelliklere sahip olanlardan daha hızlı finansmanları ayarladıklarını ifade etmişlerdir.

Gourio (2013), kurumsal sermaye yapısı tercihinin kapsayan çalışmasında, firmaların kredi marjları ile makroekonomik değişkenler arasındaki ilişkiye odaklanmıştır.

Asche, Sikveland ve Zhang (2018), firmaların büyüklük ve fiyat değişikliğinin karlılığa etkisini incelemişler. Firmaların toplam satışlarındaki artışın karlılık üzerinde olumlu bir etkiye sahip olmasına rağmen, toplam varlıkların karlılık üzerinde olumsuz etkiye sahip olduğunu bulmuştur.

Saona, Martín ve Jara (2018), kaldıraç oranı, sahiplik yapısı, firma büyüklüğü, karlılık, varlık yapısı oranı, büyüme fırsatı, borç dışı vergi kalkanı gibi sermaye yapısı faktörlerini kullanarak sermaye kararlarının da hangi faktörlerle ilişkili olduğunu belirlemiştir. Çalışmada, sahiplik yapısı ile kaldıraç oranı ilişkisini negatif diğer değişkenlerin ise pozitif etkilediğini tespit etmiştir.

Akkaynak (2022), 14 bankanın 2002-2020 yılları arasındaki sermaye yapıları belirleyicilerini panel veri analiz ile test etmiştir. Analiz sonucunda bu bankaların sermaye yapılarını belirlemede hiyerarşi teorisinin daha uyumlu olduğu tespit etmiştir.

Son yıllarda makine öğrenme ve derin öğrenme konuları diğer disiplinlerde olduğu gibi finans alanında da sıklıkla kullanılmaktadır. Finans alanında genellikle iflas tahmini ve kredi riski değerlendirmesi, hisse senedi fiyatı tahmini, portföy yönetimi, oynaklık ve likidite, kara para aklamanın önlenmesi, dolandırıcılığın önlenmesi ve risk yönetimi gibi konular olduğu görülmektedir (Ahmed ve diğerleri, 2022).

Yurt içinde makine öğrenme yöntemleri ile yapılan çalışmalara bakıldığında bu çalışmaların ülke riski tahmini (Doğan ve Türe, 2022), Borsa endeksi hareketlerinin tahmini (Pabuçcu, 2019), makine öğrenme yöntemleri ile iflas risk tahmini (Shakeri ve diğerleri, 2019), makine öğrenmesi yöntemleri sigorta şirketlerinin derecelendirilmesi ve tahmin performansının karşılaştırılması (Aksoy, 2020), Karar Ağaçları Algoritması ile Modigliani-Miller Teorilerinin Testi (Şeyranlıoğlu ve Karavardar, 2022) karşılaştırılması üzerine olduğu görülmektedir.

Yurt dışında yapılan çalışmalara bakıldığında ise, makine öğrenimi algoritmaları aracılığıyla tüketici kredi riski modelleri (Khandani ve diğerleri, 2010), döviz piyasasında algoritmik ticaret üzerine (Chaboud ve diğerleri, 2014), Chicago Board Options Exchange piyasa volatilite endeksinin modellenmesi ve tahmin edilmesi (Fernandes ve diğerleri, 2014), yapay sinir ağı kullanarak borsa endeksi tahmini (Moghaddam ve diğerleri, 2016), günlük ve anlık fiyatlara ilişkin destek vektör regresyonunu kullanarak hisse senedi fiyat tahmini (Henrique ve diğerleri, 2018) ve ağaç tabanlı sınıflandırıcılar kullanarak borsa fiyatlarının yönünü tahmini (Basak ve diğerleri, 2019) gibi çalışmaların yapıldığı görülmektedir. Çalışmanın giriş bölümünde bahsedildiği üzere daha önce sermaye yapısı kararları ile ilgili makine öğrenimi yöntemlerinin kullanılmadığı görülmekte ve ilk kez bu çalışmada makine öğrenmesi yöntemleri kullanılarak test edilmektedir.

3. VERİ SETİ VE YÖNTEM

Çalışmanın veri seti 2014-2023 yılları arasında Borsa İstanbul’da orman, kâğıt ve basım endeksinde sıralanan 15 firma arasından bahse konu yıllar arasında bilançolarına ulaşılan 9 firmadan oluşmaktadır. 1 Ocak-31 Aralık tarihleri arasındaki bilanço, nakit akış ve gelir tablosu gibi finansal tablolardan faydalanılarak değişkenlere ait veriler Kamuyu Aydınlatma Platformu’ndan elde edilmiş ve Excel ortamında analize hazır hale getirilmiştir. Araştırmada veri setini oluşturan sektör ve tarih aralığının seçilmesinin ana nedeni öncelikle üretim firmalarının mali verilerinin finansal açıdan daha sağlıklı olmasından kaynaklanmaktadır. Bu firmalar çoğunlukla kapsamlı bir varlık yapısına, sürekli nakit akışına ve ölçek ekonomilerine sahip oldukları için finansal olarak daha sağlam bir yapıya sahiptirler. Bu sektörde faaliyette bulunan 15 firmanın 6’sının yeni halka arz olmasından dolayı veri setinden çıkarılmıştır. Ayrıca seçilen firmalara ait 2014 yılı öncesi analiz edilebilir finansal verilere ulaşmada yaşanan zorluklardan dolayı tarih aralığı 2014-2023 olarak belirlenmiştir. Analizler, Python

tabanlı bir veri analiz aracı olan Orange yazılımı kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan firma bilgileri tablo 1’de gösterilmiştir.

Tablo 1. Analizde Kullanılan Firma Bilgileri

Firma Adı	Borsa Kodu
Alkim Kağıt Sanayi Ve Ticaret A.Ş.	ALKA
Bak Ambalaj Sanayi Ve Ticaret A.Ş.	BAKAB
Duran Doğan Basım Ve Ambalaj Sanayi A.Ş.	DURDO
Kaplamın Ambalaj Sanayi Ve Ticaret A.Ş.	KAPLM
Kartonsan Karton Sanayi Ve Ticaret A.Ş.	KARTN
Mondi Turkey Oluklu Mukavva Kağıt Ve Ambalaj Sanayi A.Ş.	MNDTR
Prizma Pres Matbaacılık Yayıncılık Sanayi Ve Ticaret A.Ş.	PRZMA
Saray Matbaacılık Kağıtçılık Kırtasiyecilik Ticaret Ve Sanayi A.Ş.	SAMAT
Viking Kağıt Ve Selüloz A.Ş.	VKING

Değişkenler belirlenirken sermaye yapısı ile doğrudan bağlantılı olan literatürde de sıklıkla kullanılan ve çalışmada da kullanılan bağımlı değişken, kaldıraç oranı olarak belirlenmiştir. Bağımsız değişkenler ise firma büyüklüğü, karlılık, varlık yapısı, varlık likiditesi, büyüme, özkaynak karlılığı, varlık getirisi, borç dışı vergi kalkanı ve varlık devir hızı gibi değişkenlerdir. Kaldıraç oranı, bir şirketin finansal yapısını ve borç kullanımını yansıtmaktadır. Bu nedenle, kaldıraç oranı bağımlı değişken olarak kullanılarak, şirketin finansal performansının incelenmesi ve değerlendirilmesi sağlanır. Bağımlı değişken olarak kullanıldığında, kaldıraç oranındaki değişimlerin şirketin kararlar üzerindeki etkisi incelenmektedir.

Bağımsız değişkenlere bakıldığında, özkaynak karlılığı, satışların büyüklüğü gibi faktörler, şirketin finansal performansını yansıtan önemli göstergelerdir. Bu faktörlerin kaldıraç oranı üzerindeki etkisi, şirketin karlılık düzeyi ve büyüme potansiyeli ile sermaye yapısı arasındaki ilişkiyi anlamamıza yardımcı olmaktadır. Varlık yapısı, varlık likiditesi, varlık devir hızı gibi faktörler, şirketin risk profili ve finansal durumu hakkında bilgi sağlayarak kaldıraç oranını etkileyen risk unsurlarını belirlememize yardımcı olmaktadır. Firma büyüklüğü, vergi kalkanı gibi faktörler, şirketin özelliklerini ve iş yapısını temsil etmektedir. Bu faktörlerin kaldıraç oranı üzerindeki etkisi, şirketin finansal yapısını şekillendiren farklı dinamikleri anlamamıza yardımcı olabilir. Tablo 2’de değişkenlere ait bilgiler gösterilmiştir.

Tablo 2. Çalışmada Kullanılan Bağımlı ve Bağımsız Değişken Bilgileri

Değişkenler	Oranlar	Formüller
Bağımlı Değişken	Kaldıraç Oranı	Toplam Borç/Özkaynak
	Varlık Getirisi	FAVÖK/Toplam Varlıklar
	Firma Büyüklüğü	Toplam Varlıkların Log.
	Varlık Yapısı	Toplam Satışlar/Toplam Varlıklar
Bağımsız Değişkenler	Varlık Likiditesi	Nakit ve Benzeri Değ./T. Varlıklar
	Vergi Kalkanı	Amortisman/ Toplam Varlıklar
	Varlık Devir Hızı	Toplam Satışlar/Duran Varlıklar
	Satışların Büyüklüğü	Toplam Satışların Log.
	Özkaynak Karlılığı	Net Kar/Özkaynak

Çalışmada kullanılan bağımlı ve bağımsız değişkenleri tespit etmek için sermaye yapısı üzerine yazında çoğunlukla kullanılan değişkenler seçilmiştir (Harris ve Raviv, 1991; Booth, Aivazian, Demirci-Kunt ve Maksimovic, 2001; Frank ve Goyal, 2009). Yapılan çalışmalarda değişkenlerin sermaye yapısı ile ilgili teorilerle sermaye yapısı belirleyicileri arasında ilişki ve öngörüler açıklanmıştır. Varlık getirisi oranı için hiyerarşi teorisi, bir şirketin önce iç finansman kaynaklarını kullandığı fikrine

dayanarak firmanın getirisi ile toplam borcu arasında negatif bir ilişkilidir (Myers ve Majluf, 1984). Firma büyüklüğü için takas teorisine göre, firmanın büyüklüğü ile borç oranı doğru orantılıdır (Gaud ve diğerleri, 2005). Hutchinson ve Hunter (1995) ve O'Brien ve Vanderheijden (1987), yapılan toplam varlık devir hızının borç oranı üzerinde etkisi bulunmaktadır. Sheikh ve Wang (2011), Ogiriki ve Werigbeleghe (2015), Arsov ve Naumoski (2016), çalışmalarında vergi kalkını ile borç oranı, finansal hiyerarşi ve işaret teorisine göre negatif, temsil teorisine göre ise pozitif ilişkilidir. Büyüklük ile kaldıraç oranı, hiyerarşi teorisine göre negatif dengeleme, temsil ve işaret etkisi teorisine göre ise pozitif ilişkilidir. Varlık likiditesi oranı ile borç oranı, dengeleme, temsil ve işaret etkisi teorisine göre pozitif hiyerarşi teorisine göre ise negatif ilişkili olduğunu belirtmiştir.

Çalışmada öncelikle toplanan veriler Excel’de analize hazır hale getirilmiştir. Bahse konu yıllar için oluşturulan veri setinde toplam 90 gözlem bulunmaktadır. Bu gözlemler, 9 farklı firmadan 10 yıl boyunca toplanan verilerden oluşmaktadır. Eksik veya hatalı veri kontrolü ve verilerin analizi yapılmış olup, veri seti üzerindeki değişkenlerin sağlıklı ölçülebilmesi için normalizasyon işlemi yapılmıştır. Normalizasyon yapılmasındaki temel hedef, bir araya getirilen verileri, belli bir değer aralığına toplayarak bu sayısal değerler arasındaki farklılıkları değiştirmeden aynı ölçek haline getirmektir (Dondurmacı ve Çınar, 2014: 262). Ancak literatürde ağaç tabanlı algoritmalar kullanıldığında normalizasyonun bilgi kaybına yol açtığı bundan dolayı da veri setinde normalizasyon yapmanın çoğu zaman tavsiye edilmediği ifade edilmektedir (Breiman, 2001). Çalışmada SVM ve AdaBoost algoritmaları için normalizasyon işlemi yapılmış Random Forest ve XGBoost algoritmaları için ise normalizasyon yapılmamıştır. Normalizasyon işleminin ardından veri seti %70 eğitim ve %30 test setine ayrılmıştır. Yazında yaygın bir şekilde kullanılması sebebiyle bu oranlar tercih edilmiştir. Eğitim seti ile model eğitilirken, parametre optimizasyonu yapılmıştır. Parametre optimizasyonunda her bir yöntem için kullanılan aralıklar aşağıdaki tablolarda gösterilmiştir. Bu süreç sayesinde modelin doğruluğu ve genelleme kabiliyetini en üst düzeye çıkararak aşırı öğrenme sorununu azaltmak hedeflenmiştir.

4. BULGULAR

BİST imalat sanayinde faaliyette bulunan orman, kağıt ve basım endeksinde sıralanan firmaların 2014-2023 yılları arasında kurumsal sermaye yapıları belirleyicileri ve makine öğrenmesi yöntemleri ile oluşturulan model önerisine ilişkin bulgular ve analiz sonuçları aşağıda gösterilmektedir. Tablo 3’te değişkenlerinin tanımlayıcı istatistikleri gösterilmiştir.

Tablo 3. Tanımlayıcı İstatistikler

Değişken	Ortalama	Mod	Medyan	Dağılım	Minimum	Maksimum
Kaldıraç Oranı	0.4080	0.0004	0.0333	3.8389	0.0004	13.6427
Varlık Getirisi	3.0179	0.7809	2.2007	1.4222	0.00343	27.1411
Firma Büyüklüğü	0.8862	0.0070	0.0380	2.8230	0.0070	8.8819
Varlık Yapısı	8.4093	7.8756	8.4314	0.0539	6.9997	9.3076
Varlık Likiditesi	7.4748	7.5470	8.3167	0.3486	-1.1928	9.4109
Vergi Kalkını	23.5653	-5.1826	0.1199	8.1902	-5.1826	1838.98
Varlık Devir Hızı	1.1830	0.4690	0.9940	0.8950	0.0010	8.320
Satışların Büyüklüğü	0.3433	-0.8339	0.1750	2.4087	-0.8339	5.5456
Özkaynak Karlılığı	1.4402	1.1495	1.3154	0.5284	-0.5409	3.5964

Makine öğrenmesi yöntemlerinde değerlendirme metrikleri olarak RMSE, MAE ve R2 değerleri dikkate alınmaktadır. RMSE metriği, tahmin edicinin verilere uyumunun kusur oranını göstermektedir. MAE metriği, modeldeki tahminlerin nihai sonuçlara ne kadar yakın olduğunu ölçmek için kullanılır. Yani, veri kümesinin tüm örneğinde, o örnek için gerçek değer ile öngörülen değer arasındaki her bir farkın mutlak değerinin ortalamasıdır. R2 metriği, bağımsız değişkenden tahmin edilebilen bağımlı değişkendeki varyansın oranı olarak yorumlanır. Kullanılan makine öğrenmesi yöntemlerinin model

anlamlılık değerini açıklayan R2 metriğinin değerine göre model değerlendirilmesi yapılmaktadır (Breiman, 2001; Ay, 2020).

Rastgele orman (RF) algoritması, çoklu regresyon ve sınıflandırma ağacı algoritmalarını birleştiren bir makine öğrenmesi modelidir. Bu algoritma, sağlam bir genelleme yeteneği, eğitim hızı ve yüksek hassasiyet avantajına sahiptir ve farklı özelliklerin önemini sağlayabilir. Rastgele orman algoritması, sınıflandırma ve regresyon için kullanılmaktadır (Breiman, 2001). Adaboost yöntemi, makine öğrenmesi yöntemlerinde perspektifinden ardışık topluluklar içerisinde tahmin hızı önemli bir rol oynayan bir yöntemdir. Bu yöntemin seçilmesinin nedeni ise birçok veri kümesini ve bellek alanını verimli kullanmasıdır (Basnet ve diğerleri, 2008).

SVM (Destek Vektör Yöntemi) algoritması, Cortes ve Vapnik (1995), tarafından ortaya atılan fazla ölçekli veri setinde verimli bir şekilde uygulama yapması ve doğrusal olmayan verileri işleyebilmesiyle ortaya çıkmaktadır. Gelecekte yeni veri noktalarını verimli bir şekilde sınıflandırmak ve alanı n farklı sınıfa bölen en uygun çizgiyi veya karar sınırını bulmak için kullanılmaktadır (Yang ve diğerleri, 2023). Destek vektörleri, hiper düzleme en yakın veri noktalarıdır ve hiper düzlemin yerini tespit etmektedir. Diğer makine öğrenmesi yöntemlerinden farklı olarak, SVM sadece destek vektörlerini uygulayarak veriyi böler; bu özellik sayesinde, SVM’nin daha etkin bir model oluşturmayı başarır (Burges, 1998).

XGBoost algoritması, çoğunlukla kesinlik derecesi yüksek olan büyük veri setlerinde sıklıkla kullanılan bir makine öğrenmesi algoritmasıdır. Chen ve Guestrin (2016), çalışmalarında kullanarak bu algoritmayı geliştirilmiştir. Özellikle hızlı veri işleme yüksek performans oranı ve kesinlik bakımından kuvvetli bir algoritma olarak ifade edilmektedir. XGBoost, başka boosting yöntemlerinden farklı olarak yatay işleme özelliği ile dikkat çekmekte ve fazla hiperparametre özelliğini destekleyerek çalıştırılan modeli daha elastik ve optimize edilebilir kılmaktadır. XGBoost’un çok fazla parametre ayarı ile çalışması nedeniyle kullanımı fazlaca karmaşık olabilmektedir. Özellikle veri setinin küçük boyutta olması aşırı öğrenme sorunu ortaya çıkarabilmektedir (Chen ve Guestrin, 2016).

AdaBoost, Random Forest ve SVM gibi farklı makine öğrenimi yöntemleri farklı yaklaşımlara sahip olduğu için karşılaştırılabilirler. Her birinin avantajları, dezavantajları ve kullanım alanları farklı olduğundan, bu yöntemlerin karşılaştırılması, belirli bir problem bağlamında hangi yöntemin daha iyi performans gösterebileceğini anlamak için mantıklı olabilmektedir. AdaBoost genellikle yüksek varyanslı veri setlerinde iyi performans gösterirken, Random Forest daha karmaşık veri setlerinde ve yüksek boyutlu özellik uzaylarında etkili olabilmektedir. SVM ise daha küçük veri setleri ve boyut azaltma gerektiren durumlar için tercih edilmektedir. Veri setinin boyutu, karmaşıklığı, özellik sayısı ve sınıf dengesi gibi faktörler, hangi algoritmanın en uygun olduğunu belirler. SVM düşük boyutlu ve dengeli veri setlerinde daha iyi performans gösterebilirken, Random Forest büyük boyutlu ve dengesiz veri setlerinde daha etkili olabilmektedir. Her algoritmanın belirli hiperparametreleri vardır ve bu parametrelerin uygun şekilde ayarlanması önemlidir. AdaBoost’un sayıca zayıf öğrenicileri belirlemek için kullanılan tahmin ediciler ve Random Forest’in ağaç sayısı ve derinliği gibi parametreleri vardır. Bu parametrelerin optimal değerleri, genellikle çapraz doğrulama veya başka bir hiperparametre ayarlama tekniği kullanılarak belirlenir (Sakal, 2020). Çalışmada kullanılan program özelliklerinden en uygun sonucu veren hiperparametreler çapraz doğrulama tekniği kullanılarak belirlenmiştir.

Makine öğrenimi yöntemlerinden çalışmada kullanılan yöntemlerin seçimi, genellikle projenin hedefine ve veri setinin özelliklerine bağlıdır. Örneğin, lineer regresyon basit bir modeldir ve yorumlanabilmesi yüksektir, bu nedenle veri seti ve problem belirsizlikleri kolayca yorumlanabildiğinde tercih edilmektedir. Karar ağaçları ve rastgele ormanlar ise hem sınıflandırma hem de regresyon

problemlerinde geniş bir kullanım alanına sahiptir ve doğrusal olmayan ilişkileri modelleme yetenekleri vardır. Destek vektör makineleri (SVM) ise özellikle küçük veri setlerinde etkili olabilmekte ve çoklu boyutlarda karmaşık karar sınırları oluşturabilmektedir. Makine öğrenmesi yöntemlerinde parametre seçimi ve optimizasyonu için her bir makine öğrenimi algoritması için önemli olan parametreler vardır ve bu parametrelerin optimal değerleri genellikle deneme yanılma yoluyla belirlenir veya daha sofistike yöntemler kullanılarak otomatik olarak ayarlanır. Örneğin, destek vektör makinelerinde C parametresi, karar ağaçlarında ağaç derinliği veya düğüm bölünmelerinin en az örnek sayısı gibi parametreler bulunur. Bağlantı arama, rastgele arama veya daha gelişmiş teknikler, bu parametrelerin optimize edilmesine yardımcı olabilir. Çalışmada deneme yanılma yöntemi ile en uygun sonuçları veren parametreler tercih edilmiştir (Noyan, 2019).

RMSE (Root Mean Squared Error), MAE (Mean Absolute Error) ve R2 (R-kare) gibi değerlendirme metrikleri, modelin performansını ölçmek için kullanılır. RMSE ve MAE, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçerken, R2 değeri tahmin edilen varyansın gerçek varyansa oranını ölçer. Bu metrikler, farklı açılardan model performansını değerlendirmeye yardımcı olur ve genellikle regresyon problemleri için kullanılmaktadır (Ay, 2020). Oluşturulan eğitim ve test setinin en uygun sonuçlara ulaştığı noktaya ait parametreler ile regresyon performansları aşağıdaki tablolarda gösterilmiştir.

Tablo 4. Model Optimizasyon Metrikleri

Model	N Estima.	Kern.	Max D.	C	Learn Rate	Eps.	Max-İter	Min Samp Split	Min SampLeaf
R.F	50-100-150	-	5-10-15	-	-	-		2-4-6-10	1-2-4-5
A.Bosst	10-50-100	-	-	-	0.01-0.1-1.0	-		-	-
XGB	30-50-100	-	2-3-5	-	0.01-0.03-0.05-0.1	-		-	-
SVM	-	Lin.-Rbf – Poly-Sig.	-	0.1-1-10	-	0.1-0.2	1000.0	-	-

Tablo 4’te kullanılan modellerin değerlendirme metrikleri ve en uygun değerlendirme metrikleri ile elde edilen en iyi performans metrikleri gösterilmektedir. Bu metrikler deneme yanılma yoluyla tespit edilmiştir. Random Forest modeli için en uygun performans metrikleri, N estimators (150), max depth (10), min samples split (4) ve min samples leaf (2) parametreleri ile en uyumlu sonuca ulaşılmış diğer parametreler default olarak tercih edilmiştir. AdaBoost modeli için en uygun performans metrikleri, N estimators (10) ve learning rate (0.01) parametreleri ile aşırı öğrenme sorununu en aza indirilmiş ve en uyumlu sonuca ulaşılmış diğer parametreler default olarak tercih edilmiştir. XGBoost modeli için en uygun performans metrikleri, N estimators (30), max depth (2) ve learning rate (0.03) parametreleri ile en uyumlu sonuca ulaşılmış diğer parametreler default olarak tercih edilmiştir. SVM modeli için en uygun performans metrikleri, kernel optimizasyonu ile yapılan denemeler sonucunda doğrusal kernel

(Linear), veri yapısına en uygun sonucu vermiştir. Diğer parametreler deneme yanılma yoluyla C (1), epsilon (0.1) ve Max-İter (1000.0) parametreleri ile en uyumlu sonuca ulaşılmış diğer parametreler default olarak tercih edilmiştir.

Tablo 5. Model Performans Sonuçları

Model	RMSE	MAE	Eğitim Perf. R ²	Test Perf. R ²
R.F	0.42	0.25	0.91	0.87
A.Bosst	0.46	0.27	0.89	0.86
XGB	0.42	0.24	0.95	0.88
SVM	0.45	0.35	0.88	0.84

Tablo 5’te modellerin model performans sonuçlarına bakıldığında Random Forest modeli, ağaç tabanlı yöntemlerin sağlamlığı sayesinde yüksek performans göstermiştir. Optimize edilmiş parametreler, aşırı öğrenme riskini kontrol altında tutmuştur. Test verisinde doğruluk yüksek çıkmış ancak hata metriklerinden MAE ve RMSE değerleri kabul edilebilir düzeyde kalmaktadır. Bu performans sonucu ile genel olarak dengeli ve güçlü bir model olarak değerlendirilebileceği anlaşılmaktadır. AdaBoost modeline ait performans sonuçları, eğitim ve test doğruluk oranları birbirine yakın ve yüksek (%89 ve %86). Bu, aşırı öğrenme riskinin düşük olduğunu ve modelin iyi genelleme yaptığını gösterir. RMSE ve MAE değerleri kabul edilebilir seviyede olup, modelin makul bir tahmin kapasitesine sahip olduğunu işaret etmektedir. AdaBoost modelinin hem eğitim performansı hem de test setinde doğruluk yüksek çıkmıştır. Random Forest’e göre test verisinde daha düşük bir performans sağlıyor ve bu modelin yeni verilere genellenebilirliğini sınırlandırmakta olduğu göstermektedir. XGBoost modeline ait performans sonuçları, eğitim ve test verilerinde dengeli bir performans sunmaktadır. Eğitim setinde yüksek doğruluk sağlarken (R2: 0.95), test verisinde de oldukça iyi bir doğruluğa sahip (R2: 0.88). Test ve eğitim sonuçları arasındaki farkın kabul edilebilir düzeyde kalması, modelin aşırı öğrenmeden kaçındığını ve genelleme yeteneğinin iyi olduğunu gösteriyor. Bu nedenle, XGBoost modeli güçlü bir performans sunan dengeli bir model olarak karşımıza çıkmaktadır. SVM modeline ait performans sonuçları, eğitim verisinde (%88) ve test verisinde (%84) doğruluğu, SVM modelinin dengeli bir performans sergilediğini göstermektedir. RMSE ve MAE değerleri, kabul edilebilir hata seviyelerini işaret etmektedir.

SONUÇ

Bu çalışma, belirli kurumsal sermaye yapılarını belirleme sürecini ilk olarak regresyon analiz ve ikinci olarak makine öğrenmesi yöntemlerinin uygulanması amacıyla gerçekleştirilmiştir. Kurumsal sermaye yapısının doğru bir şekilde hesaplanması, finansal kararların ve firmaların performansının bakış açısıyla değerlendirilmesi büyük bir değere sahiptir. Bu araştırma, 2014-2023 dönemi boyunca BİST’de halka açık orman, kâğıt ve basım endeksinde sıralanan 15 firma arasından bahse konu yıllar arasında bilançolarına ulaşılan 9 firmanın sermaye yapısının sektöre özgü belirleyicilerini incelemek ve makine öğrenmesi yöntemleri ile model oluşturduğu için oldukça kapsamlıdır.

Araştırmada, bir dizi makine öğrenmesi modelinin tipik kurumsal sermaye yapılarının belirlenmesine yönelik oluşturulan modelde, Random Forest, AdaBoost, XGBoost ve SVM algoritmaları kurumsal sermaye yapısının tahmin edilmesi için kullanılmıştır. Analiz sonucuna çalışmada kullanılan modellerin eğitim ve test performansları değerlendirildiğinde, XGBoost, eğitim sırasında güçlü öğrenme kapasitesi ve test verisinde sergilediği yüksek genelleme performansı ile öne çıkmaktadır. Random Forest, dengeli bir yapı sergilemiştir. AdaBoost, makul düzeyde dengeli sonuçlar sunmuş ancak tahmin hataları diğer modellere kıyasla biraz daha yüksek olduğu görülmektedir. SVM, diğer modellere kıyasla genelleme kapasitesinde sınırlı bir performans göstermiştir ve tahmin hatalarının daha büyük olduğu gözlemlenmiştir. Genel olarak, XGBoost, tüm modeller arasında genelleme

kapasitesi ve hata oranları açısından en iyi performansı sergileyerek önerilen yöntem olmuştur. Random Forest ve XGBoost en iyi sonuçları sağladığı görülmektedir. Her iki model de test verisinde dengeli ve yüksek doğruluk sağladığı anlaşılmaktadır. XGBoost yönteminin, aşırı öğrenme riski olmadan biraz daha dengeli performans sunmasıyla daha iyi performans sağladığını söyleyebiliriz. SVM modelinin ise model sonuçlarına bakıldığında diğer modellere göre daha düşük performans gösterdiği anlaşılmaktadır.

Bu araştırmanın, işletme ve finans yönetimi alanında çalışanlara, iş dünyası paydaşlarına ve politika yapıcılarına, kurumsal sermaye yapısı yönetimi ve alınacak sermaye yapısı kararlarında tartışılan hususların anlaşılmasına yardımcı olacağı düşünülmektedir. Ayrıca bu çalışma kurumsal sermaye yapılarını analiz ve tahmin etmek için AdaBoost gibi makine öğrenmesi yöntemlerinin kullanılmasının firmalar ve paydaşları için faydalı olabileceğini göstermektedir. Ancak, makine öğrenmesi ile sermaye yapısı kararları üzerine gelecek çalışmalar için daha fazla veri ve değişkenlerin kullanılması ile yapılacak tahminlerin performansını arttırabileceği düşünülmektedir.

Etik Beyan

Çalışma Etik Kurul onayını gerektiren bir çalışma değildir.

Katkı Oranı Beyanı

Yazar çalışmanın yazılmasından taslağın oluşturulmasına kadar tüm süreçlerde bulunmuş ve nihai halini okuyarak onaylamıştır.

Çatışma Beyanı

Yapılan bu çalışma gerek bireysel gerekse kurumsal/örgütsel herhangi bir çıkar çatışmasına yol açmamıştır.

KAYNAKÇA

- Ahmed, S., Alshater, M. M., El Ammari, A. ve Hammami, H. (2022). Artificial Intelligence and Machine Learning in Finance: A Bibliometric Review. *Research in International Business and Finance*, 61, 101646.
- Akkaynak, B. (2022). Sermaye Yapısı Teorileri ve Türk bankacılık Sisteminin Sermaye Yapısı Belirleyicileri. *Akdeniz İİBF Dergisi*, 22(1), 57-68.
- Aksoy, B. (2020). Sigorta Şirketlerinin Derecelendirilmesinde Makine Öğrenmesi Yöntemleri Tahmin Performansının Karşılaştırılması: Türkiye Örneği. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 12(23), 579-597.
- Allen, D. E. (1991). The Determinants of Capital Structure of Listed Australian Companies: The Financial Manager’s Perspective. *Australian Journal of Management*, 16(2), 103-128.
- Anwar, W. (2012). Cross-Industry Determinants of Capital Structure: Evidence from Pakistani Data, *International Journal of Management and Innovation*, 4(1), 79-86.
- Arsov, S. ve Naumoski, A. (2016). Determinants of Capital Structure: An Empirical Study of Companies from Selected Post-Transition Economies. *Journal of Economics and Business*, 34(1), 119-146.
- Asche, F., Sikveland, M. ve Zhang D. (2018). Profitability in Norwegian Salmon Farming: The impact of Firm Size and Price variability, *Aquacult. Econ. Manag.*, 22 (3), 306-317.

- Soydaş, Ş. S. (2025). Makine Öğrenmesi Yöntemleri İle Sermaye Yapısının Belirlenmesi; BİST’TE Uygulama. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 27(48), 94-110.
- Ay, Ş. (2020, Nisan). Model Performansını Değerlendirmek–Metrikler. <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1>.
- Basak, S., Kar, S., Saha, S., Khaidem, L. ve Dey, S. R. (2019). Predicting the Direction of Stock Market Prices Using Tree-Based Classifiers. *The North American Journal of Economics and Finance*, 47, 552-567.
- Basnet, R., Mukkamala, S. ve Sung, A. H. (2008). Detection of Phishing Attacks: A Machine Learning Approach. In *Soft Computing Applications in Industry* (ss. 373-383). Springer, Berlin, Heidelberg.
- Bauer, P. (2004). Determinants of Capital Structure: Empirical Evidence from Czech Republic. *Czech Journal of Economics and Finance*, 54(1-2), 2–21.
- Bokpin, G. A. (2009). Macroeconomic Development and Capital Structure Decisions of Firms: Evidence from Emerging Market Economies. *Studies in Economics and Finance*, 26(2), 129–142. <http://dx.doi.org/10.1108/10867370910963055>.
- Bontempi, M. E. (2002). The Dynamic Specification of the Modified Pecking Order Theory: It’s Relevance to Italy. *Empirical Economics*, 27, 1- 22.
- Booth, L., Aivazian, V., Demircuc-Kunt, A., ve Maksimovic, V. (2001). Capital Structures in Developing Countries. *The Journal of Finance*, 56(1), 87-130.
- Breiman, L. (2001). Random Forest. *Machine Learning*, 45(1), 5- 32.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167. <https://doi.org/10.1023/A:1009715923555>.
- Chaboud, A. P., Chiquoine, B., Hjalmarsson, E. ve Vega, C. (2014). Rise of the Machines: Algorithmic Trading in the Foreign Exchange Market. *The Journal of Finance*, 69(5), 2045-2084.
- Chen, T. ve Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- Cortes, C. ve Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>.
- Dang, V. A., Kim, M. ve Shin, Y. (2012). Asymmetric Capital Structure Adjustments: New Evidence From Dynamic Panel Threshold Models. *Journal of Empirical Finance*, 19(4), 465-482.
- De Jong, A., Kabir, R. ve Nguyen, T., T. (2008). Capital Structure Around the World: The Roles of Firm- and Country-Specific Determinants. *Journal of Banking & Finance*, 32 (2008), 1954-1969.
- Doğan, S. ve Türe, H. (2022). Makine Öğrenmesi Teknikleri ile Ülke Riski Tahmini. *Fiscaeconomia*, 6(3), 1126-1151.
- Dondurmacı, G. A. ve Çınar, A. (2014). Finans Sektöründe Veri Madenciliği Uygulaması. *Akademik Sosyal Araştırmalar Dergisi*, 2(1), 258-271.
- Fernandes, M., Medeiros, M. C. ve Scharth, M. (2014). Modeling and Predicting the CBOE Market Volatility Index. *Journal of Banking & Finance*, 40, 1-10.

- Soydaş, Ş. S. (2025). Makine Öğrenmesi Yöntemleri İle Sermaye Yapısının Belirlenmesi; BİST’TE Uygulama. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 27(48), 94-110.
- Frank, M. Z. ve Goyal, V. K. (2009). Capital Structure Decisions: Which Factors are Reliably Important? *Financial Management*, 38(1), 1–37. <http://dx.doi.org/10.1111/j.1755-053X.2009.01026.x>.
- Gaud, P., Jani, E., Hoesli, M. ve Bender, A. (2005). The Capital Structure of Swiss Companies: An Empirical Analysis Using Dynamic Panel Data. *European Financial Management*, 11(1), 51-69.
- Gourio F. (2013). Credit Risk and Disaster Risk. *Am. Econ. J. Macroecon.*, 5(3), 1-34.
- Graham, J. R. ve Leary, M. T. (2011). A Review of Empirical Capital Structure Research and Directions for the Future. *Annu. Rev. Financ. Econ.*, 3(1), 309-345.
- Graham, J. R., Leary, M. T. ve Roberts, M., R. (2015). A Century of Capital Structure: The Leveraging of Corporate America. *Journal Of Financial Economics*, 118(3), 658-683.
- Harris, M. and Raviv, A. (1991). The Theory of Capital Structure. *The Journal of Finance*, 46(1), 297-355.
- Henrique, B. M., Sobreiro, V. A. ve Kimura, H. (2018). Stock Price Prediction Using Support Vector Regression on Daily and up to the Minute Prices. *The Journal of Finance and Data Science*, 4(3), 183-201.
- Hutchinson, R. ve Hunter, R. (1995). Determinants of Capital Structure in the Retailing Sector in the UK. *The International Review of Retail, Distribution and Consumer Research*, 5(1), 63-78.
- İskenderoğlu, Ö., Karadeniz, E. ve Atioğlu, E. (2012). Türk Bankacılık Sektöründe Büyüme, Büyüklük ve Sermaye Yapısı Kararlarının Kârlılığa Etkisinin Analizi. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 7(1), 291-311.
- Jensen, M. C. (1986). Agency Costs of Free Cash Flow, Corporate Finance and Takeovers. *The American Economic Review*, 76(2), 323-329.
- Jensen, M. C. ve Meckling, W. H., (1976). Theory of the Firm: Managerial Behavior, Agency Costs and Ownership Structure. *J. Financ. Econ.*, 3(4), 305-360.
- Katagiri, M., (2014). A Macroeconomic Approach to Corporate Capital Structure. *Journal of Monetary Economics*, 66, 79-94.
- Kesgin, H. T., Shakeri, S., Bulut, N., Yüzük, S., ve Aktaş, M. S. (2019). Bankruptcy Risk Forecast Based on Company Balance Sheet Data Using Machine Learning. In *2019 4th International Conference on Computer Science and Engineering (UBMK)* (ss. 195-200). IEEE.
- Khandani, A. E., Kim, A. J., ve Lo, A. W. (2010). Consumer Credit-Risk Models via Machine-Learning Algorithms. *Journal of Banking & Finance*, 34(11), 2767-2787.
- Kouki, M. ve Said, H. B. (2012). Capital Structure Determinants: New Evidence from French panel Data. *International Journal Of Business and Management*, 7(1), 214–229.
- Kraus, A. ve Litzenberger, R. H. (1973). A State-Preference Model of Optimal Financial Leverage. *The Journal of Finance*, 28(4), 911-922.
- Külter, B. ve Demirgüneş, K. (2007). Perakendeci Firmalarda Kârlılığı Etkileyen Değişkenler: Hisse Senetleri İMKB’de İşlem Gören Perakendeci Firmalar Üzerinde Ampirik Bir Çalışma. *Ç.Ü. Sosyal Bilimler Enstitüsü Dergisi*, 16(1), 445-460.

- Soydaş, Ş. S. (2025). Makine Öğrenmesi Yöntemleri İle Sermaye Yapısının Belirlenmesi; BİST’TE Uygulama. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 27(48), 94-110.
- Leland, H. E. ve Pyle, D. H. (1977). Informational Asymmetries, Financial Structure and Financial Intermediation. *The Journal of Finance*, 32(2), 371-387.
- Lemmon, M. L., Roberts, M. R. ve Zender, J. F. (2008). Back to the Beginning: Persistence and the Cross-Section of Corporate Capital Structure. *The Journal of Finance*, 63(4), 1575-1608.
- Li, L. ve Islam, S., Z., (2019). Firm and Industry Specific Determinants of Capital Structure: Evidence from the Australian Market. *International Review of Economics & Finance*, 59, 425-437.
- Lööf, H. (2003). Dynamic Optimal Capital Structure and Technological Chang. *Center for European Economic Research*, Discussion Paper, 3 – 6.
- Modigliani, F. ve Miller, M., H. (1958). The Cost of Capital, Corporation Finance And The Theory Of Investment. *American Economic Review*, 48(3), 261-297.
- Modigliani, F. ve Miller, M., H., (1963). Corporate Income Taxes and the Cost of Capital: A correction. *The American Economic Review*, 53(3), 433-443.
- Moghaddam, A. H., Moghaddam, M. H. ve Esfandyari, M. (2016). Stock Market Index Prediction Using Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.
- Myers, S. ve Majluf N. (1984). Corporate Financing and Investment Decisions When Firms Have Information That Investors Do Not Have. *Journal of Financial Economics*, 13, 187-221.
- Myers, S., C. (1984). The Capital Structure Puzzle. *J. Finance*, 39(3), 574-592.
- Nguyen, T. ve Wu, J. (2011). Capital Structure Determinants and Convergence. *Bankers, Markets and Investors*. 111, 43-53.
- Nimalathasan, B. (2010). Capital Structure and Its Impact on Profit Ability: A Study of Listed Manufacturing Companies in SRI Lanka. *Ekonomika, Journal for Economic Theory and Practice and Social Issues*, 56(4), 83-92.
- Noyan, M. (2019, Ekim). Yeni Başlayanlar için Makine Öğrenmesi Algoritmaları. <https://merveenoyan.medium.com/yeni-ba%C5%9Flayanlar-i%C3%A7in-makine-%C3%B6%C4%9Frenmesi-algoritmalar%C4%B1-6b89b3a67750>.
- O’Brien, T. ve Vanderheiden, P. (1987). Empirical Measurement of Operating Leverage for Growing Firms. *Financial Management*, 16(2), 45-53.
- Ogiriki, T. ve Werigbelegba, A. P. (2015). Determinants of Capital Structure and Firm’s Performance in Nigeria (1989-2014): An Empirical Investigation Approach. *International Journal of Management and Economics Invention*, 1(10), 471-479.
- Pabuççu, H. (2019). Borsa Endeksi Hareketlerinin Tahmini: Trend Belirleyici Veri. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 22(1), 246-256.
- Pratheepkanth, P. (2011). Capital Structure and Financial Performance: Evidence from Selected Business Companies in Colombo Stock Exchange SRI Lanka. *Researchers World*, 2(2), 171-183.
- Qian, Y., Tian, Y. ve Wirjanto, T. N. (2007). An Empirical Investigation into the Capital-Structure Determinants of Publicly Listed Chinese Companies. *SSRN eLibrary*.
- Ross, S. A. (1977). The Determination of Financial Structure: The Incentive Signalling Approach. *The Bell Journal of Economics*, 8(1), 23- 40.

- Soydaş, Ş. S. (2025). Makine Öğrenmesi Yöntemleri İle Sermaye Yapısının Belirlenmesi; BİST’TE Uygulama. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 27(48), 94-110.
- Sakal, M. (2020, Haziran). Makine Öğrenmesi Algoritmaları Kısa Açıklamaları. <http://muratsakal.com/?p=230>.
- Saona, P., Martín, P. S. ve Jara, M. (2018). Group Affiliation and Ownership Concentration as Determinants of Capital Structure Decisions: Contextualizing the Facts for an Emerging Economy. *Emerging Markets Finance & Trade*, 54, 3312-3329.
- Sheikh, N., A. ve Wang, Z. (2011). Determinants Capital Structure, an Emprical Study of Firms in Manufacturing Industry of Pakistan. *Managerial Finance*, 37(2), 117-133.
- Shubita, M. F. ve Alsawalhah, J. M. (2012). The Relationship Between Capital Structure and Profitability. *International Journal of Business and Social Science*. 3(16), 104-112.
- Sufi, A. (2009). The Real Effects of Debt Certification: Evidence from the Introduction of Bank Loan Ratings. *Review of Financial Studies*, 22(4), 1659-1691.
- Şahin, O. (2011). KOBİ’lerde Finansal Performansı Belirleyen Faktörler. *ZKÜ Sosyal Bilimler Dergisi*. 7(14), 183-200.
- Şeyranlıoğlu, O. ve Karavardar, A. (2022). Karar Ağaçları Algoritması ile Modigliani-Miller Teorilerinin Testi: Holding Şirketleri Üzerine Bir Uygulama. *Asya Studies*, 6(21), 303-316.
- Terim, B. ve Kayalı, C. (2009). Sermaye Yapısını Belirleyici Etmenler: Türkiye’de İmalat Sanayi Örneği. *Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 7(1),125-154.
- Ulusoy, T. (2008). Systematic Risk and Firm Financial Structure: Evidence on Istanbul Stock Exchange. *The Business Review*, Cambridge, 11(2), 226-231.
- Yang, C. J., Huang, W. K. ve Lin, K. P. (2023). Three-Dimensional Printing Quality Inspection Based on Transfer Learning with Convolutional Neural Networks. *Sensors*, 23(1), 491.

Extended Abstract

Machine Learning Methods in Capital Structure Decisions; Application in BIST

This study was conducted to create a model based on machine learning management dataset to identify and develop firm-specific factors that significantly affect firms' funding decisions. The study consists of 9 firms whose balance sheets were accessed from the Public Disclosure Platform (KAP) between the years 2014-2023 among the 15 firms listed in the forest, paper and printing index of Borsa Istanbul. The main reasons for choosing this sector are that it is in the manufacturing sector, machine learning methods have not been used in this sector, and there is no previous study on the determinants of capital structures of such firms.

While determining the variables, the dependent variable, which is frequently used in the literature and is directly related to capital structure, was determined as the leverage ratio. The independent variables are variables such as firm size, profitability, asset structure, asset liquidity, growth, return on equity, asset return, non-debt tax shield and asset turnover. The leverage ratio reflects the financial structure and debt usage of a company. Therefore, by using the leverage ratio as a dependent variable, the financial performance of the company is examined and evaluated. When used as a dependent variable, the effect of changes in the leverage ratio on the company's decisions is examined. When looking at the independent variables, factors such as return on equity and sales volume are important indicators reflecting the company's financial performance. The effect of these factors on the leverage ratio helps us understand the relationship between the company's profitability level and growth potential and its capital structure. Factors such as asset structure, asset liquidity, and asset turnover provide information about the company's risk profile and financial situation, helping us determine the risk elements affecting the leverage ratio.

In the study, firstly the collected data was prepared for analysis in Excel. There are 90 observations in the data set created for the mentioned years. These observations consist of data collected from 9 different companies for 10 years. By checking for missing or incorrect data, the data is analyzed and normalization is performed in order to measure the variables on the data set healthily. The main goal of normalization is to collect the data brought together into a certain value range and to bring them to the same scale without changing the differences between these numerical values (Dondurmacı and Çınar, 2014: 262). However, it is stated in the literature that when tree-based algorithms are used, normalization causes loss of information and therefore normalization in the data set is often not recommended (Breiman, 2001). In the study, normalization was performed for SVM and AdaBoost algorithms, but no normalization was performed for Random Forest and XGBoost algorithms. After the normalization process, the data set was divided into 70% training and 30% test sets. These rates were used because they are widely used in the literature. While training the model with the training set, parameter optimization was performed. The ranges used for each attribute for parameter optimization are shown in the tables below for each method. With this process, it is aimed to reduce the over-learning problem by maximizing the accuracy and generalization ability of the model.

In the research, in the model created to determine the typical corporate capital structures of a series of machine learning models, Random Forest, AdaBoost, XGBoost and SVM methods were evaluated with comprehensive analyses and different methods for estimating the corporate capital structure. When the training and test performances of the models used in the study were evaluated as a result of the analysis, XGBoost stands out with its strong learning capacity during training and high generalization performance on the test data. Random Forest exhibited a balanced structure. AdaBoost provided reasonably balanced results, but it was seen that the prediction errors were slightly higher compared to the other models. SVM showed limited performance in generalization capacity compared to the other models and it was observed that the prediction errors were larger. In general, XGBoost was the recommended method by showing the best performance in terms of generalization capacity and error rates among all the models. It was seen that Random Forest and XGBoost provided the best results. It was understood that both models provided balanced and high accuracy on the test data. We can say that the XGBoost method provided better performance by providing a slightly more balanced performance without the risk of over-learning. When looking at the model results, it is understood that the SVM model shows lower performance than other models.
