

Makine Öğrenmesi ile Nakit Akış Tablosu Üzerinden Kredi Skorlaması: XGBoost Yaklaşımı*

Credit Scoring on Cash Flow Table with Machine Learning: XGBoost Approach

Güner ALTAN¹ , Server DEMİRCİ² 

ÖZ

Modernleşme ve globalleşmeyle birlikte makine öğrenmesi yöntemleri bankacılık ve finans sektöründe artan bir ivmeyle kullanılmaya başlanmıştır. Özellikle bankacılık sektöründe sunulan kredi ürünlerinin artmasıyla kötü ve iyi müşteriler arasında tam olarak ayırt etme yeteneği son derece önemli hale gelmiştir. Bu ayırt etme yeteneği sadece bankaların karlılıklarını artırmakla kalmaz, aynı zamanda pazardaki rekabet gücünü de artırır. Bu bağlamda bankalar firmaları borçlandırmadan önce kredi değerlendirme sürecinden geçirirler ve bu sürecin en önemli ayağını da şüphesiz skorlama çalışması oluşturmaktadır. Bankaların taşıdığı en önemli risklerden birinin kredi riski olduğu düşünülürse kredi değerlendirme sürecinde skorkart çalışmasının da doğru, güvenilir ve hızlı bir şekilde sonuçlanmasının önemi yadsınamaz. Skorlama çalışmalarında firmanın solo ya da grup firması olması firmanın ya da firmaların değerlendirilmesini değiştirebilir. Grubu oluşturan firmalarda ana firma statüsündeki firmanın derecelendirme notu ne kadar iyi olursa olsun diğer firmaların notu düşük ise, konsolide derecelendirme notunu etkileyip düşürebilir. Bu kapsamda çalışmada grup firmalarına vurgu yapılmıştır. Çalışmanın amacı konsolide firmaların nakit akış tablosundan faydalanılarak bir skorkart modeli geliştirilmeye çalışılmasıdır. Python program dili makine öğrenmesi ile XGBoost, Gradient Boosting ve Neural Network yöntemleri kullanılmıştır. Bu üç yöntem karşılaştırılmış olup XGBoost yöntemi %80 doğruluk skoru ile tercih edilen model olmuştur.

Anahtar Kelimeler: Makine öğrenmesi, XGBoost, Kredi Skorlama, Python, Neural Network

Jel Sınıflaması: C13, C62, C69

ABSTRACT

Machine learning methods have started being used with greater momentum in the banking and finance sectors alongside modernization and globalization. The ability to distinguish between good and bad customers has become extremely important, especially with the increase



DOI: 10.26650/JEPR1114842

*Bu çalışma Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü Bankacılık Doktora programında Prof. Dr. Server DEMİRCİ danışmanlığında yürütülen doktora tezinden üretilmiştir.

¹Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Bankacılık Anabilim Dalı, İstanbul, Türkiye

²Marmara Üniversitesi, Bankacılık ve Sigortacılık Yüksekokulu, Bankacılık Bölümü, İstanbul, Türkiye

ORCID: G.A. 0000-0001-6189-7104;
S.D. 0000-0003-3930-3554

Sorumlu yazar/Corresponding author:

Güner ALTAN,
Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Bankacılık Anabilim Dalı, İstanbul, Türkiye
E-posta/E-mail: guner.altan@vakifbank.com.tr

Başvuru/Submitted: 10.05.2022

Revizyon Talebi/Revision Requested:
08.06.2022

Son Revizyon/Last Revision Received:
09.06.2022

Kabul/Accepted: 09.06.2022

Atıf/Citation: Altan, G. & Demirci, S. (2022). Makine öğrenmesi ile nakit akış tablosu üzerinden kredi skorlaması: XGBoost yaklaşımı. *İktisat Politikası Araştırmaları Dergisi - Journal of Economic Policy Researches*, 9(2), 397-424. <https://doi.org/10.26650/JEPR1114842>



in credit products offered in the banking sector. This ability to distinguish not only increases banks' profitability but also increases their competitiveness in the market. In this context, banks put companies through a credit evaluation process before loaning to them, and the most important leg of this process is undoubtedly the credit score analysis. Considering that one of the most important risks banks carry is credit risk, the importance of correctly, reliably, and quickly completing the balanced scorecard study during the credit evaluation process cannot be denied. Whether the company undergoing a scorecard study is an independent company or part of a group of companies may change how the company or firms are evaluated. In a group of companies, no matter how good a rating one company has in regard to its status within the parent company, if the other companies have low ratings, this may affect and reduce the consolidated rating. In this context, the current study focuses on groups of companies. The aim of the study is to try to develop a scorecard model using the cash flow statements of consolidated companies. In this study, eXtreme Gradient Boosting (XGBoost), Gradient Boosting and Artificial Neural Network algorithms which are machine learning techniques and Python program were used. These three methods were compared, and the extreme gradient boosting method was shown to be the preferred model with an accuracy rating of 80%.

Keywords: Machine Learning, XGBoost, Credit Scoring, Python, Artificial Neural Network

Jel Classification: C13, C62, C69

EXTENDED ABSTRACT

The study obtained 399 observations over a 3-year review period between 2017 and 2019 for 133 consolidated companies. The study aims to provide a faster and more reliable model for producing results with regard to banks' scoring/rating studies based solely on cash flow statements in terms of companies' financial data. In essence, the XGBoost algorithm was used in the Python machine learning methods to attempt to show that companies can indeed perform a successful scoring study using their cash flow statements.

With the increased competition in the banking sector, having banks maintain their assets with sustainable profitability is extremely important for both customer satisfaction and banks. Credit score analyses are a laborious, attention-gaining study process. Banks have been researching the most accurate credit risk assessment methods for many years. New methods have started being used alongside the developments in technology. One of these can be machine learning algorithms using the program Python.

By abandoning the traditional statistical methods in the banking sector, a new model with modern methods has been presented to the banking and financial sectors that uses machine learning algorithms. With regard to the data set, the study has selected consolidated companies compiled from manufacturing, trade, and service sectors and excluding construction sectors. At the same time, the study has preferred consolidated companies because of the great importance group companies have with regard to the credit evaluation process. By developing a model in this context, the study intends to emphasize how important the consolidated (i.e., group company) credit score is in the credit evaluation process in the case of a balanced scorecard study.

Firstly, the study will present the introduction and discuss the literature review and then talk about the concept of group companies and their credit evaluation process. The following sections of the study will address the three algorithms of extreme gradient boosting, gradient boosting, and neural networks, which are machine learning techniques used in credit scoring.

The study's pre-model preparation phase discusses the details of the dependent and independent variables and conducts pre-model data cleaning. Correlation analyses (feature-to-feature correlations, feature-to-target correlations) were performed in this context, and the outlier values were determined for the data. The outlier values for the variables were not extracted from the data, as removing them from the data would reduce the number of observations. Instead, the Robust Scaler method, which is sensitive to outliers, was used to scale the data.

During the phase of setting up the model, training and test set partitioning involved the following. A cross-validation analysis was performed on the training set, and the training set was divided into five subsets. As a result, the cross-validation training and test set accuracy score results were compared. The test results from the model were determined to have an 80% accuracy score in XGBboost (eXtreme gradient boosting), a 77.5% accuracy score for gradient boosting, and a 61.25% accuracy score for the artificial neural networks.

The study has preferred the XGBoost algorithm model with its 80% accuracy score and 82% score for area under the receiving operating characteristics curve (ROC-AUC). The model's ROC curve is shown in figure 12, and the area below the curve (AUC) is 82%. The XGBoost's confusion matrix is also shown in figure 8 and reveals our model's predictive performance power. In this context, the probability of success is estimated based on a 52% classification threshold using 80 observational test data with the model possessing the highest performance. Ratings of A, B, C, D, or E were given to the companies based on their probability of success.

This study presents a model that is able to provide companies with a reliable scorecard/rating model in a shorter time by taking only their cash flow statement in terms of financial data. In this way, banks can manage risk appetite with maximum optimization and provide extra customer satisfaction with faster analyses. This study involves rapid credit score rating and can at the very least provide solutions to companies' short-term loan demands.

1. Giriş

Kredi skorlaması, finansal uzmanların bir kredi başvurusunu kabul edip etmeme konusunda daha iyi kararlar almalarına yardımcı olur, böylece temerrüt olasılığı yüksek olan firmaların başvuruları kabul edilmeyebilir (Demajo, Vella & Dingli, 2020). Temerrüt olasılığı düşük olan firmaların da kredileri kabul edilmekle birlikte kredi risk yönetimi daha iyi bir teminat yapısı (temerrüt halinde kayıp), fiyatlama ve uygun bir vade ile yönetilebilir.

Günümüzde kredi skorlaması veya içsel derecelendirmeye dayalı yaklaşım, bir firmanın bankaya karşı finansal yükümlülüklerini yerine getirip getirmeme gücünü değerlendirmek için bankacılık faaliyetlerinde yaygın olarak kullanılmaktadır. Dolayısıyla bankaların kredi faaliyetlerinde risk değerlendirme ve tanımlama fonksiyonları da oldukça önemlidir. Kredi değerlendirme süreci müşterilere göre değişir. Bu süreç, kredi derecelendirme ve değerlendirme sürecinde finansal ve finansal olmayan bilgi ve belgelere dayanmaktadır.

Kredi skorlama kredi risk yönetiminin çekirdek sürecidir. Temelde krediye başvuran müşterileri iyi müşteri ve kötü müşteri olarak ikiye ayırmaktadır. Bu nedenle aslında skorlama çalışması bir sınıflandırma problemini çözme yöntemidir. Kredi skorlama çalışmaları müşteri veri setinde dengesiz veri setiyle bir sınıflandırma yapar ve maliyeti minimize eder (Chen vd., 2019). Bu bağlamda iyi ve kötü müşterileri doğru bir şekilde ayırtmak ve bu süreci en hızlı şekilde sonuçlandırmak doğru model ve yöntem ile mümkündür.

Skorlama çalışması kredi riski analizine büyük katkı sağlamaktadır. Kredi riski analizi müşterileri kategorize edilmesinde önemli bir rol oynar ve bu da yukarıda da bahsedildiği gibi müşterilerin iyi ve kötü olmak üzere iki gruba ayrılmasını sağlar. Son yıllarda kredi risklerini analiz etmek için birçok model ve sınıflandırma algoritması uygulanmaktadır (Sang, Nam & Nhan, 2016).

Kredi skorlama çalışmaları genellikle firmaların finansal ve finansal olmayan bilgi ve belgeleri üzerinde oluşan bilgilere dayanmaktadır. Ancak bankacılık sektöründe rekabetin artması, müşterilerin daha hızlı bir dönüş beklemesi ve tabii ki bankaların da müşterileri ayırt etmede doğru karar vermesi her iki taraf için de önemlidir. Bu bağlamda firmaların nakit akış tablosunun önemi vurgulanmalıdır. Bir firmanın belki de sadece nakit akış tablosuna bakarak firmanın temerrüde düşüp düşmeyeceği tahmin edilebilir. Nakit akış tabloları aynı zamanda bilanço ve gelir tablosundan beslendiğinden bunu söylemek yanlış olmayacaktır. Tabii ki gerek skorlama çalışmasında olsun gerekse de derecelendirme çalışmasında olsun firmaların finansal olmayan bilgi ve belgelerine de ihtiyaç duyulmaktadır. Ancak hızlı bir skorlama çalışmasında finansal veri anlamında firmaların sadece nakit akış tablosundan hareket etmek en azından bankaların verdiği kısa vadeli ürünler için hızlı ve güvenilir bir çözüm olabilir.

Son zamanlarda bankacılık ve finans sektöründe meydana gelen gelişmeler; bankaların, firmaların kredi riskini değerlendirirken daha ihtiyatlı olunmasına zemin hazırlamıştır. Bu bağlamda kredi skorlama modellerini doğru oluşturmak, firmaların kredi riskini değerlendirmek ve olası riskleri azaltmak için birincil yollardan biri olmuştur. Dolayısıyla bankalarında kullandığı skorkart modelleri zamanla gelişmiş ve evrimleşmiştir. Skorkart modelleri; istatistiki ve makine öğrenme yöntemleri olarak ikiye ayrılmaktadır. Son zamanlarda ise istatistiki çalışmalar yanı sıra yapay zekâ temelli makine öğrenmesi yöntemleri tercih edilmektedir (Wang vd., 2011). Skorlama modelleri ile ilgili yapılan çalışmalar incelendiğinde ise yapay zekâ temelli makine öğrenmesinde kullanılan algoritmaların kullanıldığı görülmektedir.

Çalışmada konsolide firmaların tercih edilmesinin sebebi grup kredilerine dikkat çekilmesidir. Bu bağlamda kredi değerlendirme sürecinde solo firma ile grup firma değerlendirmesinde teknik olarak skorlama yöntemleri aynı olabilir. Ancak grubun risk değerlendirme sürecinde bankaların daha detaylı bir çalışma yapması gerekebilir. Derecelendirme çalışmalarında ana firmaya verilen rating notu grubun diğer üyelerini etkileyebilir. Bu nedenle kavramsal olarak grup firma ve kredi değerlendirme süreçlerine kısaca değinilecektir.

Çalışmanın konusu konsolide firmaların nakit akış tablosundan yola çıkarak python programı makine öğrenmesi aracılığıyla bir skorkart modeli geliştirmesidir. Bu kapsamda Aşırı Gradyan Artırma (XGBoost), Gradyan Yükseltme (Gradient Boosting) ve Yapay Sinir Ağları (Neural Network) algoritmaların karşılaştırılmıştır. Çalışma neticesinde XGBoost yönteminin firmaların başarılı ve başarısız olarak sınıflandırma konusunda tahmin gücünün kuvvetli olduğu görülmüştür. Dolayısıyla model seçiminde XGBoost algoritması %80 doğruluk skoru ile tercih edilen yöntem olmuştur.

2. Literatür

Literatürde kredi skorlaması ile ilgili birçok çalışma mevcuttur. Özellikle geleneksel yöntemler dediğimiz istatistiki yöntemlerin ağırlıkta olduğu söylenebilir. Yurt dışı çalışmalar incelendiğinde ise son zamanlarda makine öğrenmesi ile ilgili çalışmaların daha yoğun olduğu görülmektedir. Yurt içi literatür çalışmalarında ise python program dili makine öğrenmesi ile ilgili çalışmalara az rastlanmıştır.

Sang, Nam ve Nhan (2016), kredi skorlaması çalışmalarında öz nitelik seçimine dikkat çekerek makine öğrenmesi Rassal Orman (Random Forrest) algoritmasının sınıflandırıcı gücü ile başvuru sahiplerinin kredi risklerini değerlendirmek için Paralel Rastgele Orman sınıflandırıcısı ve özellikle seçim yöntemine dayalı bir kredi skorlama modeli önerilmiştir. Bu model ile birlikte daha hızlı ve daha doğru bir sonuç vermesi öngörülmüştür.

Qin ve ark. (2021), çalışmalarında son yıllarda makine öğrenmesi algoritmalarının skorlama çalışmalarında tatmin edici bir performansa sahip olduğunu belirtmişlerdir. Bu bağlamda karar ağaçları yönteminin kompleks korelasyona sahip bir veri seti ile karşılaştırıldığında yanlı bir sonuç verilebileceği bu nedenle bu yanlı sonucu engellemek için Aşırı Gradyan Artırma (XGBoost) modelini önermişlerdir. Önerilen model, uyarlanabilir parçacık sürüsü optimizasyonuna dayanan bir XGBoosting kredi puanlama modeline dayanmaktadır.

Li ve Chen (2020), çalışmalarında makine öğrenmesinde kullanılan yeni modelleri önermişlerdir. Kolektif öğrenme metotları olan Random Forrest, AdaBoost, XGBoost, LightGBM performanslarını karşılaştırmışlardır. Çalışma neticesinde XGBoost'un performansının rekabet edilebilir olduğu ifade edilmiştir.

Salvaire (2019), çalışmasında XGBoost algoritmasının «kötü» ile «iyi» müşterileri ayırt etmede istatistiksel olarak kullanılan yöntemlerden daha yüksek performanslı olduğunu gözlemlemiştir.

Ampountolas ve ark. (2021), çalışmalarında bireysel müşteriler için kredi değerlendirme süreçlerinde kredibilitesini ölçmek için makine öğrenmesinde bazı algoritmaları karşılaştırmıştır. Çalışma neticesinde Rassal Ormanlar (Random Forrest) algoritmasının performansının yüksek olduğunu göstermişlerdir.

Demajo ve ark. (2020), bireysel müşteriler için doğru, açıklanabilir ve yorumlanabilir bir skorlama modeli önermişlerdir. Makine öğrenmesi ve yapay zekâ tekniklerine dayanan yöntemlerin yorumlanabilirliğinin güç olduğunu belirterek yaptıkları çalışmada XGBoost yönteminin daha yorumlanabilir bir model olarak önermişlerdir.

Can (2020), çalışmasında bireysel müşteriler için kredi risk analizinde bulunmuştur. Söz konusu çalışmada 1000 kişinin çeşitli özelliklerini barındıran german credit data UCI veri seti kullanılmış olup XGBoost sınıflandırıcısında %75,60 başarı oranı yakalamıştır.

Akpınar (2019), çalışmasında bireysel müşteriler için bir skorkart modeli önermiştir. Bu bağlamda lojistik regresyon, gradyan arttırma, rastgele ormanlar ve karar ağacı modelleri olmak üzere dört makine öğrenmesi tekniği kullanmıştır. Bu modeller arasında %78 ile en iyi çalışan modelin gradyan arttırma modeli olduğu görülmüştür.

3. Kavramsal Çerçeve

Çalışmada nakit akış tablosuna dayanarak bir kredi değerlendirme modeli oluşturulduğundan kavramsal olarak konsolide firma, nakit akış tablosu, grup firma tanımından ve grup firmalarının kredi değerlendirme süreçlerinden bahsedilecektir. Aynı zamanda modelde kullanılan algoritmalara değinilecektir.

3.1. Konsolide Firma

Konsolide finansal tablolar, ana ortaklığın ve onun bağlı olduğu ortaklıklarının varlıklarının, borçlarının, öz kaynaklarının, gelirlerinin, giderlerinin ve nakit akışlarının tek bir işletmeninki gibi sunulduğu, bir gruba ait finansal tablolar olarak tanımlanmaktadır (Üçoğlu & Fırat, 2019). Bu bağlamda firmaların birbiri ile sermaye, yönetim ilişkisinin bulunması ya da borç alacak ilişkisinin bulunması neticesinde finansal konsolidasyona dahil olan firmalara konsolide firma denilebilir.

Konsolide finansal tablolar, hukuki olmaktan ziyade ekonomik bir zorunluluktur. Hukuki zorunluluk olmadığı halde finansal tabloların konsolidasyonu işletmelerin ekonomik zorunluluğundan dolayı hazırlanmaktadır. O zaman konsolide finansal tablolarda, işletmelerin dönen varlıkları, duran varlıkları, kısa vadeli yabancı kaynakları, uzun vadeli yabancı kaynakları, öz kaynakları ile gelir ve giderleri konsolide edilir. Ana ortaklık yapıları aynı olan birkaç işletmenin tek bir işletmeymiş gibi hareket edilerek finansal tabloların hazırlanması ve bu hazırlanan tabloların bütünleştirilmiş hali sadece bir işletmenin faaliyetlerini yansıtacak şekilde düzenlenmesi gerekir. Hazırlanan bu tablolar aslında tek bir işletmeye aitmiş gibi tasarruf sahiplerine, yatırımcılara, devlete ve diğer ilgili kişi ve kurumlara bilgi vermek ve sunmak için düzenlenmektedir (Yalçın, 2020).

3.2. Nakit Akış Tablosu

Nakit akış tablosu, bir faaliyet dönemi içinde bir firmada ortaya çıkan nakit akışlarını işletme faaliyetlerine, yatırım faaliyetlerine ve finansman faaliyetlerine göre gösteren bir tablodur. Nakit akış tablosu, nakit giriş ve çıkışlarını göstermekle birlikte finansal tablo kullanıcılarına nakit akışı hakkında bilgi vermekte, nakit ve nakit benzeri varlıkların kalanındaki değişimin dönem karı tutarından neden farklı olduğu hakkında aydınlatmaktadır. Yani gelir tablosu ile nakit akış tablosunun neden farklı olduğu hakkında detaylı bilgi vermektedir. Bu farklılığın sebebi ise gelir tablosunun hem tahakkuk esasına hem de nakit esasına göre düzenlenmesidir. Nakit akış tablosu ise sadece nakit esasına göre düzenlenmektedir (Akdoğan ve Tenker, 2007).

Bir firmanın gelir tablosu ve bilançosu o firmanın finansal durumu ve performansı hakkında bilgi verir. Ancak, bilançodaki bilgiler statik olduğundan ve gelir tablosunun da nakit akışına sebep olmayan kalemler içermesinden dolayı, bu iki tablo işletmenin borçlarını ödeme gücünü belirlemede yetersiz kalabilir. Diğer bir ifadeyle tahakkuk esasına göre düzenlenen bilanço ve gelir tablosu, finansal performansın ölçülmesinde yetersiz kalabilmektedir (Girgin, 2020). Bu kapsamda finansal veri anlamında bir firmayı nakit akış tablosuna bakarak değerlendirmek yanlış olmayacaktır. En azından bankanın kısa vadeli ürünler için değerlendirebileceği firmalarda hızlı bir skorlama çalışması ile değerlendirilebileceği düşünülmektedir.

3.3. Grup Firma Kavramı

Bir bilançonun varlıkları ve borçları ile gelir tablosuna yansıyan gelir/gider kalemleri, sadece tek bir firmadan kaynaklanıyorsa, söz konusu işletmeyi “solo” yani münferit firma olarak adlandırabiliriz. Ancak her işletme tek başına çalışmayabilir. Bir işletme başka bir işletmenin resmi olarak iştiraki ya da bağlı ortaklığı olabileceği gibi gizli ortağı da olabilir. Bu bağlamda eğer bir işletmenin bilanço ve gelir tablosu başka bir işletme ya da işletmelerin varlık ve yükümlülüklerinden etkileniyorsa, ayrıca yönetimi tek elden gerçekleştiriliyorsa söz konusu firmalara grup firması denilebilir. Bu grup yapılarını genellikle holding yapılarında görebildiğimiz gibi kobi segmentinde olan firmalarda da görebiliriz.

Söz konusu açıklamalardan da hareketle, birbirinden ayrı tüzel kişiliğe sahip ancak yönetim açısından bağımlı ve/veya faaliyet birlikteliği bulunan birçok ortaklığın bir araya gelmesine “grup firması” denilebilir (Akdoğan & Tenker, 2007).

3.4. Grup Firmalarının Kredilendirilmesi

Bankalar kredi değerlendirme süreçlerinde müşteriyi daha iyi tanımak ve doğru ürünü, doğru müşteriye pazarlayabilmek adına işletmeleri analiz eder. Kredi değerlendirme sürecinin en önemli ayağını bu noktada derecelendirme çalışması oluşturmaktadır. Çünkü firmaların detaylı analiz aşamasından oluşan bu süreç firma lehine çalışılıp çalışılmayacağına fotoğrafını gösterir. Firmalara yapılan derecelendirme çalışması sonucunda firmanın rating notuna/ temerrüt olasılığına bakılarak, bankanın kredi politikası gereği çalışılmayacak bir firma olması durumunda firma ile yol ayırımına gidilebilir ya da çalışma sınırlı tutulabilir.

Bankalar firmaları değerlendirirken sadece borçlandıracağı firmayı değerlendirmeyebilir. Bu durumda risk grubunda gördüğü bir ya da birkaç firmayı değerlendirme grubunda inceleyebilir. Bu noktada banka yine kendi kredi politikası doğrultusunda firmaları konsolide olarak değerlendirmek durumunda kalabilir.

Kredilendirme sürecinde grup firmaların finansal analizi, kredi analizi ve dolayısıyla firmanın risk analizine katkı sağlamaktadır. Grup analizi, firmanın değerini ve işin kalitesinin belirlenmesine, yönetimin faaliyetlerinin başarısının veya başarısızlığının ortaya çıkmasına, firmanın dış şoklara karşı sağlamlığının ölçülmesine, kredi analizi açısından en önemlisi olan, firmanın yükümlüklerini yerine getirebilme kapasitesinin ölçülmesine olanak sağlamaktadır (Fidan, 2009).

3.5. Kredi Skorlamasında Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, sadece mühendislik alanında değil teknolojik gelişmelerle birlikte finans sektöründe de büyük bir yer kazanmıştır. Bu bağlamda bu teknolojinin maliyetleri

düşürmesi ve risk yönetiminin verimliliğini artırması, ekonomi dünyası tarafından benimsenmesinde etkili olmuştur (Kassiani, 2021).

Makine Öğrenimi (ML) Algoritmaları ve yapay zekâ son yıllarda risk yönetimini başarılı bir şekilde yönetmek adına daha ön plana çıkmıştır. Günümüzde bilgisayar teknolojisinin gelişmesi ile daha kompleks modeller basit bir şekilde kullanılmaktadır (Nehrebecka, 2018).

Makine öğrenimi tabanlı sistemler, çoğu disiplindeki araştırma uygulamalarında popülerlik kazanmaktadır. Verilerden elde edilen önemli karar verme bilgisi, denetimli sınıflandırma problemleri için karar verme ağacı tabanlı topluluk tekniklerinin tanındığı geniş makine öğrenimi alanında edinilmiştir. Bu nedenle, sınıflandırma, önemli veri sınıflarını tanımlarken modelleri formüle eden veri madenciliğinde önemli bir veri analizi şeklidir. Bu bağlamda bu tür modeller, kullanıcılara büyük ölçüde verilerin daha iyi anlaşılmasını sağlayabilen kategorik sınıf etiketlerini tahmin etmektedir (Ampountolas vd., 2021).

3.5.1. Aşırı Gradyan Artırma (XGBboost)

Aşırı Gradyan Artırma (XGBboost) tipik olarak karar ağaçları olan bir dizi modele dayanan ve nihai bir model üreten kolektif bir öğrenme algoritmasıdır. Sinir ağlarının ağırlıklarını optimize etmek için kullanılır. Aşırı Gradyan Artırma (Extreme Gradient Boosting), en iyi modeli belirlerken daha ayrıntılı yaklaşımları dikkate alan bir gradyan yükseltme şeklidir. Maliyeti en aza indirir, aşırı uyumu azaltır (overfitting) ve model genelmesi performansını iyileştiren bir modeldir. XGBboost'un yorumlanması hızlıdır ve büyük boyutlu veri kümelerini iyi bir şekilde işleyebilir (Sarker, 2021).

Veri madenciliği yarışmalarındaki itibarı göz önüne alındığında, XGBboost algoritması önerilen bir çözüm olarak uygulanmaktadır. Aşırı gradyan artırma anlamına gelen XGBboost, gradyan artırma karar ağacı algoritmasını uygular. Bu isim, yeni model eklendikten sonra maliyeti en aza indirmek için gradyan iniş algoritmasını kullanmasından kaynaklanmaktadır. XGBboost algoritmasının önemli ölçüde büyümesi ve hem araştırma hem de endüstri projelerinde uygulanması, kullanım kolaylığına, yürütme hızına, özelleştirilmiş değerlendirme ve parametre ayarlama olasılığına bağlanabilir. Bu algoritma hem regresyon hem de sınıflandırma problemlerinde çözüm üretebilmektedir. (Terko vd., 2019).

3.5.2. Gradyan Güçlendirme (Gradient Boosting)


Gradyan Güçlendirme, makine öğrenmesi algoritmalarında benzer modellerde sıklıkla kullanılan bir diğer yöntemdir. Güçlendirmenin ardındaki kavram şu şekildedir, modeller sırasıyla eğitilir ve her yeni model bir önceki modelin kusurlarını düzeltmeye odaklıdır. Başlangıçta karar ağacı dataya uygundur ve daha sonra bir diğer karar ağacı sırayla yeni bir karar ağacı modelini daha önceki çıktılar ile tahmin edebilir. Bu süreç parametreler belirli

bir eşiğe ulaşana kadar devam eder (Hıld, 2021). Bu model hata teriminin artımlı olarak en aza indirilmesi yoluyla tahmin gücünün doğruluğunu artıran kolektif bir algoritmadır. İlk temel öğrenen (çoğunlukla bir ağaç) yetiştirildikten sonra, serideki her ağaç, hatayı azaltmak amacıyla önceki ağaçlardan gelen tahminin «sözde artıklarına» uygun hareket eder (Brown & Mues, 2012).

3.5.3. Yapay Sinir Ağları (Neural Network)

Yapay sinir ağları, biyolojik sinir ağlarının yapısından ve işlevsel yönlerinden ilham alan öğrenme algoritmalarıdır. Modern sinir ağları doğrusal olmayan istatistiksel veri modelleme araçlarıdır. Genellikle girdiler ve çıktılar arasındaki karmaşık ilişkileri modellemek, verilerdeki kalıpları bulmak ve gözlemlenen değişkenler arasında bilinmeyen bir ortak olasılık dağılımındaki istatistiksel yapıyı yakalamak için kullanılırlar. Yapay sinir ağları genellikle birbirleri arasında mesaj alışverişinde bulunan birbirine bağlı «nöronların» sistemleri olarak sunulur. Bağlantılar, deneyimlere dayalı olarak ayarlanabilen sayısal ağırlıklara ve öğrenme yeteneğine sahip olup bu da onları girdilere uyarlanabilir hale getirmektedir (Guegan & Hassani, 2018).

Şekil 1. Yapay Sinir Ağları



Kaynak: Ustalı, Tosun & Tosun, 2020.

Yapay Sinir Ağları, yukarıdaki şekilden de görüleceği üzere insan beyninin özelliklerinden yola çıkarak geliştirilen bir metottur. Büyük ölçüde tecrübe edinmiş bilgiyi korumaya çalışan ve bilginin daha fazlasını kullanmaya çalışan paralel işlemciler olarak tanımlanmaktadır (Ghodselaht & Amirmadhi, 2011).

4. Uygulama-Veri Seti


Çalışmanın veri setinin hazırlanması iki aşamadan oluşmaktadır. Öncelikle bağımlı değişken için başarılı ve başarısız kriterlere uyan firmalar tespit edilmeye çalışılmıştır.

Bağımlı değişken için yeterli sayıda firma tespit edildikten sonra model hazırlığına başlanmıştır. Veri seti Kamu Aydınlatma Platformunda (KAP) borsaya kote konsolide firmalardan derlenmiştir. İnşaat sektörü hakediş esasına göre çalıştığından bu çalışmadan muaf tutulmuş olup ticaret, imalat, hizmet ve eğitim sektörleri çalışmaya dahil edilmiştir. Aynı zamanda ülkemizi ve tüm dünyayı etkisi altına alan covid-19 pandemisi nedeniyle firmaların 2020 nakit akış tablolarının gerçeği yansıtmayacağı düşünüldüğünden çalışmaya dahil edilmemiştir. Nihai olarak 133 konsolide firmanın 2017-2018-2019 dönemlerine ait nakit akış tablosu temin edilmiştir.

4.1. Bağımlı Değişkenin Belirlenmesi

Modelin bağımlı değişkeni, başarılı (1) ve başarısız firma (0) olmak üzere 2 kategoriden oluşmaktadır.

Grafik 1. Modelde bağımlı değişkeni oluşturan başarısız firma sayılarının yıllara göre dağılımı



Literatür incelendiğinde finansal başarısızlık hakkında birçok çalışma bulunmaktadır. Bu bağlamda çalışmamızda başarısız firmaları tespit ederken literatürden derlenen kriterlerden yola çıkılmıştır. Aşağıdaki kriterlerden herhangi birini taşıyan firma, söz konusu yıl için başarısız firma olarak belirlenmiştir.

Tablo 1: Başarısız Firma Kriterleri

İşletmenin en az iki yıl üst üste zarar etmiş olması,
İşletmenin aktif büyüklüğünün bir önceki yıla göre en az %10 azalması,
İşletmenin öz kaynaklarının bir önceki yıla göre en az %10 azalması,
Sermayesinin yarısının veya 2/3'ünün kaybolması,
Net işletme sermayesinin negatif olması (dönen varlıklar-kısa vadeli yabancı kaynaklar)
Son iki dönem nakit açığı olan firmalar

Kaynak: Literatür incelenerek yazarlar tarafından derlenmiştir.

4.2. Bağımsız Değişkenlerin Belirlenmesi

Nakit akış tablosundaki 202 kalemden, değişkenlerin varyansına bakılarak ayrıştırıcı gücüne bakılmıştır. Böylelikle varyansı düşük olan değişkenler modelden çıkartılmış olup 202 değişken 64 değişkene indirgenmiştir. Değişkenlere nümerik kodlar verilmiş olup tabloda en solda görülmektedir. Ayrıca bağımsız değişkenler arasında korelasyon ilişkisine de bakılmış olup korelasyon ilişkisi yüksek olan değişkenler modele dahil edilmemiştir.

Tablo 2: Bağımsız Değişkenler

Değişken	Değişken İsmi	Unique Sayısı
34	Vadeli Satışlardan Kaynaklanan Kazanılmamış Finansman Geliri	108
33	Vadeli Alımlardan Kaynaklanan Ertelemiş Finansman Gideri	123
47	Öz kaynak Yöntemiyle Değerlenen Yatırımların Dağıtılmamış Karları ile İlgili Düzeltmeler	127
96	Ertelemiş Gelirlerdeki (Müşteri Sözleşmelerinden Doğan Yükümlülüklerin Dışında Kalanlar) Artış (Azalış)	130
99	Faaliyetlerle İlgili Diğer Yükümlülüklerdeki Artış (Azalış)	160
132	Maddi Olmayan Duran Varlık Alımından Kaynaklanan Nakit Çıktıları	164
83	İlişkili Taraflara Ticari Borçlardaki Artış (Azalış)	169
98	Faaliyetlerle İlgili Diğer Varlıklardaki Azalış (Artış)	172
67	İlişkili Taraflardan Ticari Alacaklardaki Azalış (Artış)	173
26	Diğer Karşılıklar (İptalleri) ile İlgili Düzeltmeler	175
53	Maddi Duran Varlıkların Elden Çıkarılmasından Kaynaklanan Kayıplar (Kazançlar) ile İlgili Düzeltmeler	175
40	Gerçeğe Uygun Değer Kayıpları (Kazançları) ile İlgili Düzeltmeler	184
199	Yabancı Para Çevrim Farklarının Nakit ve Nakit Benzerleri Üzerindeki Etkisi	187
10	Stok Değer Düşüklüğü (İptali) ile İlgili Düzeltmeler	192
180	Kredi Geri Ödemelerine İlişkin Nakit Çıktıları	196
93	İlişkili Olmayan Taraflara Faaliyetlerle İlgili Diğer Borçlardaki Artış (Azalış)	199
72	İlişkili Olmayan Taraflardan Faaliyetlerle İlgili Diğer Alacaklardaki Azalış (Artış)	203
20	Dava ve/veya Ceza Karşılıkları (İptali) ile İlgili Düzeltmeler	205
128	Maddi Duran Varlıkların Satışından Kaynaklanan Nakit Girişleri	208
175	Kredilerden Nakit Girişleri	208
37	Gerçekleşmemiş Yabancı Para Çevrim Farkları ile İlgili Düzeltmeler	208
86	Çalışanlara Sağlanan Faydalar Kapsamında Borçlardaki Artış (Azalış)	220
68	İlişkili Olmayan Taraflardan Ticari Alacaklardaki Azalış (Artış)	226
84	İlişkili Olmayan Taraflara Ticari Borçlardaki Artış (Azalış)	236
131	Maddi Duran Varlık Alımından Kaynaklanan Nakit Çıktıları	242
81	Peşin Ödenmiş Giderlerdeki Azalış (Artış)	243
3	Sürdürülen Faaliyetlerden Dönem Karı (Zararı)	251
8	Alacaklarda Değer Düşüklüğü (İptali) ile İlgili Düzeltmeler	267
31	Faiz Gelirleri ile İlgili Düzeltmeler	269
97	İşletme Sermayesinde Gerçekleşen Diğer Artış (Azalış) ile İlgili Düzeltmeler	279
52	Duran Varlıkların Elden Çıkarılmasından Kaynaklanan Kayıplar (Kazançlar) ile İlgili Düzeltmeler	283

112	Çalışanlara Sağlanan Faydalara İlişkin Karşılıklar Kapsamında Yapılan Ödemeler	290
32	Faiz Giderleri ile İlgili Düzeltmeler	291
179	Borç Ödemelerine İlişkin Nakit Çıkışları	313
114	Vergi İadeleri (Ödemeleri)	320
155	Vergi İadeleri (Ödemeleri)	320
195	Vergi İadeleri (Ödemeleri)	320
7	Değer Düşüklüğü (İptali) ile İlgili Düzeltmeler	337
91	Faaliyetler ile İlgili Diğer Borçlardaki Artış (Azalış) ile İlgili Düzeltmeler	342
174	Borçlanmadan Kaynaklanan Nakit Girişleri	342
19	Çalışanlara Sağlanan Faydalara İlişkin Karşılıklar (İptali) ile İlgili Düzeltmeler	346
127	Maddi ve Maddi Olmayan Duran Varlıkların Satışından Kaynaklanan Nakit Girişleri	355
70	Faaliyetlerle İlgili Diğer Alacaklardaki Azalış (Artış) ile İlgili Düzeltmeler	356
50	Vergi (Geliri) Gideri ile İlgili Düzeltmeler	374
30	Faiz (Gelirleri) ve Giderleri ile İlgili Düzeltmeler	383
130	Maddi ve Maddi Olmayan Duran Varlıkların Alımından Kaynaklanan Nakit Çıkışları	392
158	Finansman Faaliyetlerinden Nakit Akışları	394
201	Dönem Başı Nakit ve Nakit Benzerleri	395
79	Stoklardaki Azalışlar (Artışlar) ile İlgili Düzeltmeler	395
18	Karşılıklar ile İlgili Düzeltmeler	396
63	İşletme Sermayesinde Gerçekleşen Değişimler	396
2	Dönem Karı (Zararı)	396
1	İşletme Faaliyetlerinden Nakit Akışları	396
6	Amortisman ve İtfa Gideri ile İlgili Düzeltmeler	396
82	Ticari Borçlardaki Artış (Azalış) ile İlgili Düzeltmeler	396
66	Ticari Alacaklardaki Azalış (Artış) ile İlgili Düzeltmeler	396
198	Yabancı Para Çevrim Farklarının Etkisinden Önce Nakit ve Nakit Benzerlerindeki Net Artış (Azalış)	396
100	Faaliyetlerden Elde Edilen Nakit Akışları	396
200	Nakit ve Nakit Benzerlerindeki Net Artış (Azalış)	396
5	Dönem Net Karı (Zararı) Mutabakatı ile İlgili Düzeltmeler	396
117	Yatırım Faaliyetlerinden Kaynaklanan Nakit Akışları	396
202	Dönem Sonu Nakit ve Nakit Benzerleri	396

4.3. Korelasyon Analizi


İki değişken arasındaki ilişkiye korelasyon denmektedir. Birbiri ile çok kuvvetli ilişkilere sahip değişkenler modelden çıkartılarak tekrarlı bilgi girişi engellenebilir. Korelasyon analizinde hem bağımsız değişkenlerin birbiri arasında etkileşim incelenecek olup hem de bağımlı ve bağımsız değişken arasındaki etkileşime bakılacaktır. Yapılan analiz neticesinde bağımsız değişkenler arasında yüksek korelasyon tespit edilirse (pozitif ya da negatif) modelin yanlılığının azaltılması için korelasyonu yüksek olan değişkenler modelden çıkartılacaktır.

Bağımsız değişkenlerin bağımlı değişkene etkisinin tespit edilmesi de modelin doğru çalışması için önemlidir. Bu bağlamda bağımsız değişkenin hedef değişkene (bağımlı değişkene) yüksek korelasyon olması durumunda (literatürde %80 ya da %90 üzeri olduğu belirtilmektedir) ilgili bağımsız değişkenin de öznitelikten çıkartılması modelin doğru çalışması için önemlidir.

4.4. Bağımsız Değişkenler Arasında Korelasyon İlişkisi

Modelin daha doğru sonuç vermesi ve daha sade olması için değişkenler arasında ilişkiye bakılması gerekir, eğer yüksek korelasyonlu bir ilişki varsa söz konusu değişkenler modelden çıkartılacaktır.

Grafik 2. Korelasyon Analizi Öncesi Isı Haritası




Korelasyon analizinden sonra aşağıdaki değişkenlerin korelasyonu yüksek hesaplanmış olup korelasyon ilişkisi 0.90'dan fazla olan değişkenler modelden çıkartılmıştır. Korelasyonu yüksek değişkenler aşağıda paylaşılmıştır.

Tablo 3: Birbiri ile Yüksek Korelasyon Olan Bağımsız Değişkenler

Değişken	Değişken İsim	Unique Sayısı
180	Kredi Geri Ödemelerine İlişkin Nakit Çıkışları	196
175	Kredilerden Nakit Girişleri	208
179	Borç Ödemelerine İlişkin Nakit Çıkışları	313
155	Vergi İadeleri (Ödemeleri)	320
195	Vergi İadeleri (Ödemeleri)	320
100	Faaliyetlerden Elde Edilen Nakit Akışları	396
200	Nakit ve Nakit Benzerlerindeki Net Artış (Azalış)	396
202	Dönem Sonu Nakit ve Nakit Benzerleri	396

Korelasyonu yüksek değişkenlerin öz nitelikten çıkartıldıktan sonraki ısı haritası (korelasyon ilişkisi) aşağıda paylaşılmıştır. Isı haritasına bakıldığında korelasyon öncesi mavi renk dağılımı yoğunlukta iken korelasyonu yüksek değişkenler veri setinden çıkartıldıktan sonra turuncu dağılım artmıştır.

Grafik 3. Korelasyon Analizi Sonrası Isı Haritası



4.5. Bağımsız Değişkenin Hedef Değişken ile Korelasyon İlişkisi

Bağımsız değişkenlerin birbiri ile korelasyonu ne denli önemli ise aynı zamanda bağımsız değişkenlerin bağımlı değişkene de korelasyonu o denli önemlidir. Bağımsız değişkenler hedef değişkeni etkileme oranı yüksek ise yanlış bir sonuç oluşabilir. Bunun önüne geçilmesi için korelasyonu yüksek bağımsız değişkenler modelden çıkartılır. Ancak aşağıdaki tablodan korelasyon ilişkisine bakıldığında çalışmamızda hedef değişkenimizi yüksek oranda etkileyen bir ilişki olmadığı görülmüştür (literatürde %80 ve üzeri yüksek korelasyon kabul edilmektedir). Bu bağlamda bağımsız değişkenlerin bağımlı değişkene korelasyon dağılımı makul kabul edilmektedir.

Tablo 4: Bağımsız Değişken-Hedef Değişken Korelasyon İlişkisi

Değişken	Korelasyon	Değişken	Korelasyon	Değişken	Korelasyon	Değişken	Korelasyon
2	0.31111			158	-0.00137	26	-0.03569
50	0.23044	91	0.05605	31	-0.00808	68	-0.03942
3	0.22148	201	0.04793	20	-0.01582	83	-0.05062
131	0.10277	174	0.04415	70	-0.01817	19	-0.05440
198	0.08892	53	0.03651	Yıl	-0.01901	18	-0.05808
33	0.08830	67	0.03214	47	-0.02337	72	-0.06098
52	0.06777	96	0.02408	132	-0.02364	5	-0.06222
82	0.06748	98	0.01811	97	-0.02386	128	-0.07438
1	0.06704	130	0.01778	86	-0.02551	10	-0.07574
199	0.06573	81	0.00998	127	-0.03125	79	-0.08140
112	0.06531	84	0.00128	117	-0.03454	63	-0.08885
40	0.06464	61	-0.00009	81	-0.03485	37	-0.08901

4.6. Aykırı Uçların Tespit edilmesi

Uç değerlerin tespiti için ampirik kümülatif dağılım fonksiyonlarını kullanarak denetimsiz aykırı değer algılama algoritması ile aykırı değerler tespit edilmiştir. Veri setini oluşturan firmaların nakit akış tabloları birbirinden çok farklı olduğundan bu veri setinde uç değerlerin olması beklenen bir durumdur. Bu bağlamda gözlem sayısı uç değerleri çıkartmaya uygun olmadığından modelde aykırı uçlar tespit edilmiş ancak veriden silinmemiştir. Modelin yanlı çalışmasını önlemek adına da aykırı değerlere hassas olan Robust Scaler metodu kullanılmıştır. Robust Scaler, aykırı değerlerde modelin daha iyi sonuç verebilmesi için ölçeklendirme yapan bir metottur.

4.7. Veri Setinin Eğitim-Test Seti Olarak Bölünmesi

Veri setinin (399 gözlem sayısı) %20'si test verisi, %80'i ise eğitim verisi olarak bölünmüştür. Eğitim veri setine aşırı uyumu azaltmak için çapraz doğrulama işlemi (k fold Cros Validation) uygulanmıştır. Çapraz doğrulama, modelin veriye duyarlı olup olmadığını ve abartılı bir taklit sorununa maruz kalıp kalmadığını anlamaya yarar bir tekniktir (Sorhun, 2021).

Temelde eğitim ve test bölünmesi, tüm veri setinin eğitim kümesine ve test kümesine bölüğümüz en basit modellerden biridir. Bu yöntem, özellikle veri seti çok büyük olduğunda kullanışlıdır. Bununla birlikte bu yöntemin dezavantajı da bulunmaktadır modelin doğruluğunu etkileyen yüksek varyansların çıkma sorunu olabilir.



Çapraz doğrulama modeli ise, bir eğitim ve test seti yerine, eğitim setine «kırımlar» adı verilen k sayıda setin oluşturulduğu ve daha sonra eğitim için k-1 kırımlarının alındığı ve k. katın test için alındığı bir modeldir. Bu, tüm «kırımlar» «test kırımları» olarak hareket edene kadar tekrarlanır. Bu, model farklı veriler üzerinde birden çok kez eğitildiği için çok daha iyi ve doğru bir sonuç sağlar. Böylece her tekrarda modelin uygun şekilde eğitilmesi sağlanır (Ramraj vd., 2016). Bu çalışmada eğitim seti 5 alt sete ayrılmıştır (k fold=5).

5. Metodoloji

Python programı makine öğrenmesi ile üç model karşılaştırılmıştır. Bunlar Aşırı Gradyan Artırma (XGBoost), Gradyan Güçlendirme (Gradient Boosting) ve Yapay Sinir Ağları (Neural Network) modelleridir. Model sonuçları karşılaştırılmış ve doğruluk skoru, ROC-AUC en yüksek olan model seçilmiştir.

5.1. Model Tahminleri

Makine öğrenmesinde üç model ele alınmış olup cross validation train-test sonuçları aşağıda paylaşılmıştır. Öncelikle üç modelin skor sonuçları karşılaştırılmış olup sonrasında tek tek detay sonuçlar paylaşılmıştır.




Aşırı Gradyan Artırma (XGBoost)

XGBoost modeli, makine öğrenmesi algoritmalarında tahmin gücü rekabet edilebilir olan bir model olarak bilinmektedir. Modelin train ve test doğruluk skor sonuçlarına bakılırsa skor puan farkının 0,0182 olduğu görülmektedir. Train ve test sonuçlarının minimal olması modelin bir o kadar doğru çalıştığı anlamına gelmektedir. Model seçerken train test sonuçlarının minimum olmasına dikkat edilmesi gerekir. Aşağıda cros validation sonuçları detaylı olarak paylaşılmıştır.

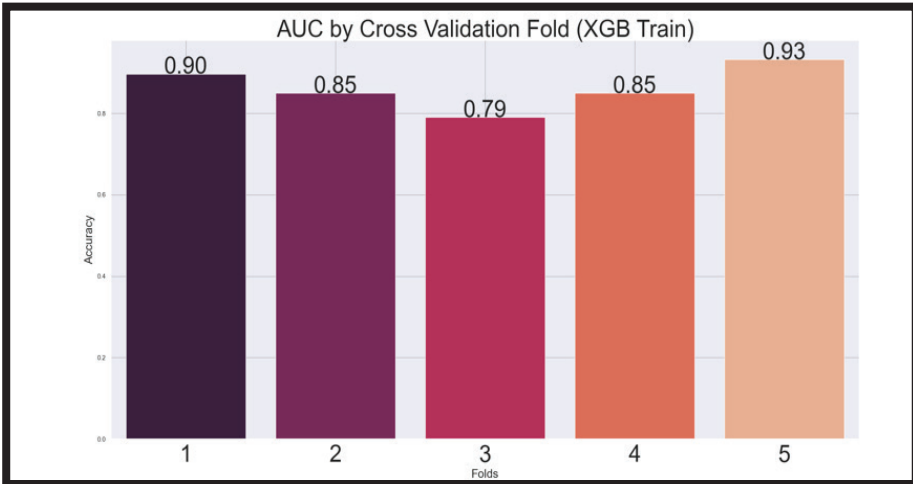
Tablo 5: Train-Test Sonuçları

Mean for CV Results XGB Train Accuracy: 0.8182
Std for CV Results XGB Train Accuracy: 0.029132481180815458
Mean for CV Results XGB Train AUC: 0.864
Std for CV Results XGB Train Accuracy: 0.04809117799793154
XGB Test Accuracy: 0.8
XGB Test AUC: 0.8169848584595129
XGB Test Precision: 0.8367346938775511
XGB Test Recall: 0.8367346938775511
XGB Test F1-Score: 0.8367346938775511

Grafik 6. Cross Validation Train Skor Sonuçları



Grafik 7. Cross Validation Train AUC (Area Under the Curve) Alan Sonuçları




Gradyan Güçlendirme (Gradient Boosting)

Modelin Cross Validation (CV) train ve test sonuçları aşağıda paylaşılmıştır.


Tablo 6: Train-Test Sonuçları

Mean for CV Results GBT Train Accuracy: 0.8088
Std for CV Results XGB Train Accuracy: 0.02254048159074369
Mean for CV Results GBT Train AUC: 0.858
Std for CV Results XGB Train Accuracy: 0.04350139405719239
GBT Test Accuracy: 0.775
GBT Test AUC: 0.7570770243581304
GBT Test Precision: 0.8297872340425532
GBT Test Recall: 0.7959183673469388
GBT Test F1-Score: 0.8125

Grafik 8. Cross Validation Train Skor Sonuçları



Grafik 9. Cross Validation Train AUC (Area Under the Curve) Alan Sonuçları


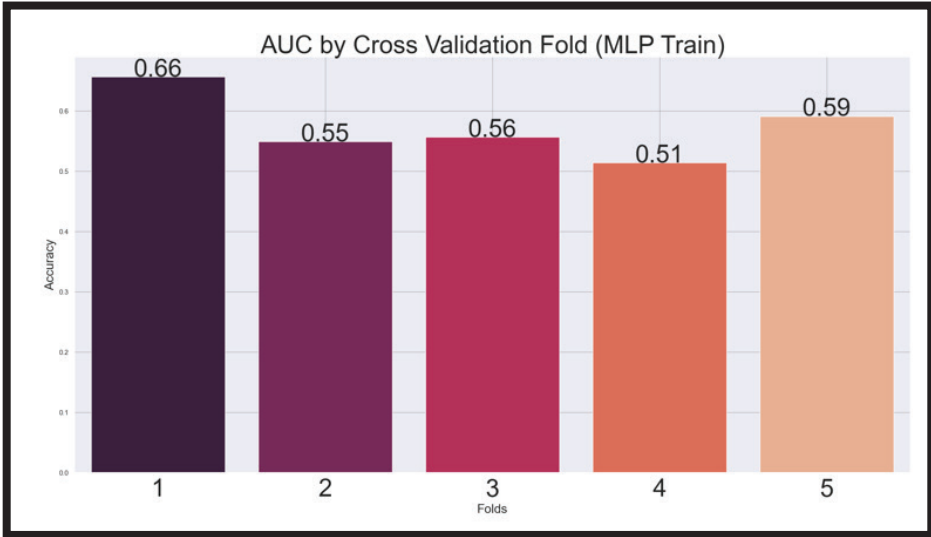


Yapay Sinir Ağları (Artificial Neural Network)

Modelin Cross Validation (CV) train ve test sonuçları aşağıda paylaşılmıştır.

Tablo 7: Train-Test Sonuçları

Mean for CV Results MLP Train Accuracy: 0.627
Std for CV Results MLP Train Accuracy: 0.003968253968253954
Mean for CV Results MLP Train AUC: 0.5737
Std for CV Results MLP Train AUC: 0.04825049377490512
MLP Test Accuracy: 0.6125
MLP Test AUC: 0.5697827518104015
MLP Test Precision: 0.6125
MLP Test Recall: 1.0
MLP Test F1-Score: 0.7596899224806202


Grafik 10. Cross Validation Train Skor Sonuçları**Grafik 11. Cross Validation Train AUC (Area Under the Curve) Alan Sonuçları**

5.2. Modelin Seçilmesi

Başarı sonuçları incelendiğinde bir firmanın nakit akış tablosunu baz alarak başarılı ya da başarısız olma durumunu (kredi verme ya da vermeme kararını) en iyi tahmin eden


modelin %80 doğruluk skoru ile XGBoost modeli olduğu görülmüştür. Denetimli öğrenme modellerinde, modelin performansını hata matrisi ve ROC-AUC eğrisi gösterebilir. Aynı zamanda skor puanını etkileyen öz nitelik (değişken) dağılımı da (feature importance) aşağıda paylaşılmıştır. Sonrasında seçilen model aracılığıyla test veri seti ile firmaların başarı olasılıkları gösterilmiş ve derecelendirme notu verilmiştir. Böylelikle bu model ile yeni bir firmanın başarı olasılığı tahmin edilip bu olasılık oranına göre derecelendirme notu verilebilirliği gösterilmeye çalışılmıştır.

Tablo 8: Hata Matrisi (Confusion Martix)




XGBoost'un tahmin performansı değerlendirilmek istenirse hata matrisi (confusion martix) adı verilen bu tablodan hareketle de hesaplama yapılabilir. Modelin doğru tahmin sayısı 64 olup bunun anlamı test veri setine verilen 80 verinin 64'nü doğru tahmin ettiği anlamına gelmektedir.

Grafik 12. ROC Eğrisi



Şekil 2. Bağımsız Değişkenlerin Bağımlı Değişkene Etki Sırası (Feature Importance)



Tablonun sol tarafı bağımsız değişkenlerin nümerik isimleridir. Sol yukarıdan aşağıya doğru bakıldığında bir firmanın XGBoost yöntemiyle başarılı ya da başarısız olmasına en çok etki eden bağımsız değişkenler gösterilmiştir (Bağımsız değişken isim detayları yukarıda tablo 2 de paylaşılmıştır).

5.3. Seçilen Model ile Firmalara Derece (Rating) Notu Verilmesi

XGBoost yöntemi ile modelimizin başarılı ve başarısız firma sınıflandırma gücünün yüksek olduğu doğruluk skoru (accuracy) ve ROC-AUC eğrisi ile gösterilmiştir. Söz konusu model ile firmaların nakit akış tablosuna bağlı kalarak başarı olasılıkları da gösterilmeye çalışılmıştır. Bu sınıflandırmada test verisi kullanılmış olup 80 gözlem ile detay sınıflandırma yapılmıştır. Bu kapsamda 80 gözlem sayımız olduğundan gözlem sayısı 5'e bölünmüş olup

derecelendirme notu başarı olasılıklarına göre yani en başarılı firmadan en başarısız firmaya A-B-C-D-E notu olmak üzere aralıklar oluşturulmuştur. Firmalar, başarılı başarısız sınıflandırılırken, sınıflandırma eşiği (classification threshold) olarak %52 eşik oran baz alınmıştır. Bu bağlamda başarı olasılığı %52 ve üzeri olan firmalar başarılı, %52 oranından aşağı olan firmalar ise başarısız olarak kabul edilmiştir. Başarılı ve başarısız aralıkları da yukarıda bahsedildiği gibi 5' bölünmüştür. Burada unutulmaması gereken söz konusu derecelendirme aralıkları bankalar arasında farklılıklar gösterilebilir. Önemli olan sınıflandırma yapılırken modelin firma sınıflandırmasında ayırt etme gücünün yüksek olması aynı zamanda firmaları başarılı başarısız olasılık oranların doğru tahminlemesidir.

Aşağıda 80 gözlemin özet sonucu bulunmaktadır. Bu bağlamda A-B-C notuna sahip 16'şar firmanın olduğu görülmektedir. D notuna sahip 14 firmanın ve E notuna sahip 18 firmanın olduğu görülmektedir. Örneğin A notuna sahip firmaların %100 olasılık oranı ile en başarılı firmalar olduğu görülürken E notuna sahip firmaların en yüksek başarı olasılığının %4 olduğu görülmüştür. C notuna sahip firmalara bakılırsa eşik değer olan minimum %52 maksimum %95 olasılık aralığı ile başarılı oldukları gösterilmiştir.

Tablo 9: Derecelendirilen Firmaların Özet Tablosu


Rating	min	max	count
E	0,00	0,04	18
D	0,05	0,42	14
C	0,52	0,95	16
B	0,96	0,99	16
A	1,00	1,00	16

Tablo 10: Derecelendirilen Firmaların Detay Tablosu

Rating	y_pred	min	max	count
E	0	0.00000	0.04000	18
E	1	NaN	NaN	0
D	0	0.05000	0.42000	14
D	1	NaN	NaN	0
C	0	NaN	NaN	0
C	1	0.52000	0.95000	16
B	0	NaN	NaN	0
B	1	0.96000	0.99000	16
A	0	NaN	NaN	0
A	1	100.000	100.000	16

Aşağıda firmaların derecelendirme (rating) notlarına göre grafik olarak da dağılımı bulunmaktadır.

Grafik 13. Firmaların Derecelendirme Notlarına Göre Dağılımı



6. Sonuç ve Değerlendirme

Bankacılık sektöründe hem rekabetin artması hem de bankaların pazarladıkları kredi hacminin artması, bankaları kredi değerlendirme süreçlerinde risklerini daha güvenilir bir şekilde yönetmelerine itmektedir. Modernleşme ve teknolojinin artmasıyla birlikte geleneksel olan istatistikî yöntemler terk edilmeye başlanmış ve makine öğrenmesiyle kredi değerlendirme süreçlerinde maksimum optimizasyon elde edilmeye çalışılmaktadır. Özellikle uluslararası bankacılık sektöründe makine öğrenmesi yöntemlerinin sıklıkla kullanıldığı yapılan literatür araştırmalarında görülmüştür.

Bankacılık sektöründe müşteriye hızlı ve güvenilir bir skorlama çalışmasının yapılması, hem müşteri hem de bankaya sağlayacağı avantajlar bakımından önem arz etmektedir. Müşteriye hızlı bir dönüşün sağlanması, müşteri memnuniyetini artıracak gibi güvenilir bir skorkart/derecelendirme çalışması, müşteriye doğru ürünün doğru teminat ve doğru vade ile pazarlanmasını sağlayacaktır. Bankanın bu anlamda risk iştahını da başarılı bir şekilde yönetmesi anlamına gelmektedir. Müşteriye doğru skorlama çalışması yapılması aynı zamanda müşterinin teminat yapısını da (temerrüt halinde kayıp) doğru bir şekilde yönetmek anlamına gelmektedir.

Çalışmada konsolide firmalar değerlendirilmiş olup grup kredisi değerlendirmelerinde konsolide notunun grubu oluşturan firmaların hepsini etkilediğine vurgu yapılmak

istenmiştir. Bu çalışmanın sadece bir skorkart modelinin geliştirilmesini değil aynı zamanda bir derecelendirme çalışmasına da ışık tutacağı düşünülmektedir. Kredi skorlaması ile ilgili çalışmalara bakıldığında özellikle bu tip çalışmaların kompleksliğinden ve tek bir çözüm için uzlaşma olmadığından bahsedilmektedir. Skorlama çalışmalarının doğruluğu ne denli önemli ise hızlı bir şekilde sonuçlandırmak da o kadar önemlidir. Bankacılık ve finans sektöründeki agresif bir rekabet ortamı olduğu düşünülürse müşteri memnuniyetinin önemine hak verilecektir.

Bu çalışmada python program dili makine öğrenmesi ile firmaların finansal veri olarak sadece nakit akış tablosu üzerinden skorkart/derecelendirme modeli geliştirilebileceği gösterilmeye çalışılmıştır. Gerek kurumsal segment firmalarda gerekse küçük ve orta segmentteki (kobi) firmalarda, solo ya da grup fark etmeksizin hızlı ve güvenilir bir modelin bankacılık ve finans sektöründe kullanılabileceği düşünülmektedir.

Rekabetin artmasıyla birlikte gerek müşteriye hızlı ve doğru bir şekilde dönmek gerekse de banka personelini gereksiz operasyonel işlemlerinden kurtarmak için hızlı skorlama/derecelendirme adı altında bu modelin kullanılabileceği düşünülmektedir.

Araştırmada makine öğrenmesinde üç algoritma karşılaştırılmış olup yapılan çalışma sonucunda Aşırı Gradyan Güçlendirme (XGBoost) yönteminin %80 doğruluk skoru, %82 AUC ile en başarılı model olduğu görülmüştür. Bu çalışmanın gelişmiş versiyonunda makine öğrenmesindeki diğer algoritmaların da sonuçları gösterilebilir.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Çalışma Konsepti/Tasarım- S.D., G.A.; Veri Toplama- S.D., G.A.; Veri Analizi/Yorumlama- S.D., G.A.; Yazı Taslağı- S.D., G.A.; İçeriğin Eleştirel İncelemesi- S.D., G.A.; Son Onay ve Sorumluluk- S.D., G.A.

Çıkar Çatışması: Yazarlar çıkar çatışması beyan etmemişlerdir.

Finansal Destek: Yazarlar finansal destek beyan etmemişlerdir.

Peer-review: Externally peer-reviewed.

Author Contributions: Conception/Design of Study- S.D., G.A.; Data Acquisition- S.D., G.A.; Data Analysis/Interpretation- S.D., G.A.; Drafting Manuscript- S.D., G.A.; Critical Revision of Manuscript- S.D., G.A.; Final Approval and Accountability- S.D., G.A.

Conflict of Interest: The authors have no conflict of interest to declare.

Grant Support: The authors declared that this study has received no financial support.

Kaynakça/References

- Akdoğan, N., & Tenker, N. (2007). *Finansal Tablolara ve Mali Analiz Teknikleri*. Ankara: Gazi Kitapevi.
- Akpınar, N. (2019). Makine Öğrenmesi Teknikleriyle Kredi Başvuru Skor Kartının Oluşturulması. (Yüksek Lisans Tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Amputolas, A., Nde, T.N., Date, P. & Constantinescu, C. (2021). A Machine Learning Approach for Micro-Credit Scoring. *Risks Journal*, 9 (50), 1-20.
- Brown, L. & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit

- scoring data sets. *Expert Systems with Applications*, 39, 3446-3453.
- Can, Ö., Y. (2020). Makine Öğrenmesi Teknikleri Kullanılarak Kredi Risk Analizi. (Yüksek Lisans Tezi). İstanbul Aydın Üniversitesi, Fen Bilimler Enstitüsü, İstanbul.
- Chen, C., Yokoyama, S., Yamashita T., & Kawamura H. (2019). Application of XGBoost to Credit Scoring. *Information processing Society Of Japan*, 194 (11), 1-8.
- Demajo, L., M., Vella, V., & Dingli, A. (2020). Explainable AI For Interpretable Credit Scoring. *Computer Science & Information Technology*, 185-203.
- Fidan, M. M. (2009). *Kredilendirme Sürecinde Uluslararası Finansal Raporlama Standartlarına Göre Konsolide Finansal Raporların Düzenlenmesi*. (Doktora Tezi). Kadir Has Üniversitesi Sosyal Bilimler Enstitüsü.
- Ghodselahi, A., & Amirmadhi, A. (2011). Application Of Artificial Intelligence Techniques For Credit Risk Evaluation. *International Journal Of Modeling And Optimization*, 1 (3), pp.246.
- Girgin, F. (2020). TMS 7 Nakit Akış Tablosu Kapsamında Finansal Performansın Ölçülmesi: Bist'te Bir Uygulama. (Yüksek Lisans Tezi). Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü.
- Grogoriou, K. (2021). Credit risk analysis via machine learning methods: client segmentation based on probability of default. (Master Thesis). University Of Macedonia, Master Of Science In Applied Informatics.
- Guegan, D., & Hassani, B. (2018). Regulatory learning: How to supervise machine learning models? An application to credit scoring. *The Journal of Finance and Data Science*, 4, 157-171.
- Hild, A. (2021). Estimating And Evaluating The Probability Of Default- A Machine Learning Approach. (Master Thesis). Uppsala Universitet, Statistics In The Faculty Of Social Sciences.
- Li, Y., & Chen, W. (2020). A Comparative Performance Assessment of Ensemble Learning for Credit Scoring. *Mathematics*, 8 (1756), 1-19.
- Nehrebecka, N. (2018). Predicting The Default Risk Of Companies. Comparison Of Credit Scoring Models: Logit Vs Support Vector Machines. *Econometrics. Ekonometria Advances in Applied Data Analysis*, 22 (2), 54-73.
- Qin, C., Zhang, Y., Bao, F., Zhang, C., Liu, P. & Liu, P. (2021). XGBoost Optimized by Adaptive Particle Swarm Optimization for Credit Scoring. *Hindawi Mathematical Problems in Engineering*, 1-18.
- Ramraj, S., Uzir, N., Sunil, R., & Banerjee, S. (2016). Experimenting XGBoost Algorithm for Prediction and Classification of Different Datasets. *International Journal of Control Theory and Applications*, 9 (40), 1-12.
- Salvaire, P. A. J. M. (2019). Explaining The Predictions Of A Boosted Tree Algorithm Application To Credit Scoring. (Master Thesis). Universidade Nova de Lisboa, NOVA Information Management School.
- Sang, H., V., Nam, N., H. & Nhan, N., D. (2016). A Novel Credit Scoring Prediction Model Based On Feature Selection Approach And Parallel Random Forest. *Indian Journal Of Science And Technology*, 9 (20), 1-6.
- Sarker, I. H. (2021), Machine Learning: Algorithms, RealWorld Applications and Research Directions. *SN Computer Science*, 2 (160), 1-21.
- Sorhun, E. (2021). *Python ile Makine Öğrenmesi*. İstanbul: Abaküs Yayınları.
- Terko, A., Žunić, E., Đonko, D., & Dželihodžić, A. (2019). Credit Scoring Model Implementation in A Microfinance Context. *International Conference On Information, Communication And Automation Technologies*, 1-6.
- Ustalı, N., K., Tosun, N., & Tosun, Ö. (2020). Makine Öğrenmesi Teknikleri ile Hisse Senedi Fiyat Tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, Cilt 16, Sayı 1, 5-8.
- Üçoğlu, D., & Fırat, F. Z. (2019). TFRS 10 Konsolide Finansal Tablolar Standardı Kapsamında Grup İçi Satışlarla İlgili Yapılan Eliminasyon İşlemlerinin Ertelenmiş Vergi Etkileri. *Muhasebe ve Denetime Bakış*, Cilt 57, s.85.
- Wang, G., Hao, J., Ma, J. & Jiang, H. (2011). A comparative assessment of ensemble learning for credit scoring. *Expert Systems with Applications*, 38, 223-230.
- Yalçın, Z. (2020). TFRS 10 Standardı Konsolide Finansal Tablolar: Bir Uygulama Örneği. *İzmir YMMO Dergisi*, 2 (2), s.3.