



**T.C.
ANKARA SOSYAL BİLİMLER ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**TİCARİ ALACAK RİSKİ YÖNETİMİ VE MAKİNE ÖĞRENMESİ
ALGORİTMALARI İLE MODELLEME: BİR MODEL ÖNERİSİ**

Yüksek Lisans Tezi

Sümeyye KAYA

**Denetim ve Risk Yönetimi Ana Bilim Dalı
Tezli Yüksek Lisans Programı**

Temmuz 2024



**T.C.
ANKARA SOSYAL BİLİMLER ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**TİCARİ ALACAK RİSKİ YÖNETİMİ VE MAKİNE ÖĞRENMESİ
ALGORİTMALARI İLE MODELLEME: BİR MODEL ÖNERİSİ**

Yüksek Lisans Tezi

Sümeyye KAYA

**Denetim ve Risk Yönetimi Ana Bilim Dalı
Tezli Yüksek Lisans Programı**

**Tez Danışmanı
Doç. Dr. Halis KIRAL**

Temmuz 2024

TEŞEKKÜR

Ankara Sosyal Bilimler Üniversite’sinde disiplinler arası bir yaklaşım ile denetim ve risk yönetimi alanlarını bir araya getiren ilk yüksek lisans programının kurucusu ve tez danışmanım Doç. Dr. Halis Kırıl’a, yüksek lisansa başlamamdaki teşviği ve süreçteki tüm destekleri için teşekkür etmek isterim. Eğitim süreci boyunca desteklerini esirgemeyen bölüm hocalarımız; Doç. Dr. Hakan Karabacak, Dr. Öğr. Üyesi Furkan Uysal ve Cem Dursun’a teşekkür ederim. Tez çalışmasına katkılarından ötürü Dr. Öğr. Üyesi Esra Satıcı ve Doç. Dr. Yenal Arslan’a ayrıca teşekkür ederim.



İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ÖZET.....	iv
ABSTRACT.....	v
KISALTMALAR.....	vi
ŞEKİL LİSTESİ.....	vii
TABLO LİSTESİ.....	viii
GİRİŞ.....	1
BÖLÜM 1: KREDİ.....	3
1.1. Kredi.....	3
1.2. Ticari Alacak Kredisi.....	6
BÖLÜM 2: KREDİ RİSKİ.....	9
2.1. Kredi Riskinin Tanımı.....	9
2.2. Kredi Riskinin Tarihçesi.....	10
2.3. Kredi Riskinin Önemi.....	16
2.4. Literatür Taraması.....	19
BÖLÜM 3: KREDİ RİSKİ DEĞERLENDİRME.....	22
3.1. Çalışmanın Amacı ve Kapsamı.....	22
3.2. Çalışmanın Kısıtları.....	23
3.3. Kredi Riski Değerlendirmesinde Kullanılan Yöntemler.....	23
3.3.1. Geleneksel Yöntemler.....	27
3.3.1.1. Geleneksel Yöntemlerin Değerlendirilmesi.....	29
3.3.1.2. Literatür Taraması.....	31
3.3.2. Makine Öğrenmesi.....	41
3.3.2.1. Makine Öğrenmesi Yöntemleri.....	44
3.3.2.2. Makine Öğrenmesi Yöntemlerinin Değerlendirilmesi.....	47
3.3.2.3. Literatür Taraması.....	49
3.4. Çalışmanın Önemi.....	61
BÖLÜM 4: UYGULAMA.....	63
4.1. Çalışmanın Yöntemi.....	63

4.2. Uygulama Öncesi Süreç.....	64
4.2.1. Keşifçi Veri Analizi (EDA).....	66
4.2.2. Veri Seti ve Veri Ön işleme.....	67
4.2.3. Özellik Mühendisliği.....	69
4.3. Uygulama ve Değerlendirme.....	71
4.3.1. Veri Setinin Eğitim-Test Seti Olarak Bölümlenmesi.....	71
4.3.2. Modelin Uygulanması ve Kalitesinin Değerlendirilmesi.....	71
4.3.3. Model Optimizasyonu ve En İyi Modelin Değerlendirilmesi.....	80
4.3.4. En İyi Model İçin Özellik Önemi.....	82
BÖLÜM 5: SONUÇ VE ÖNERİLER.....	84
KAYNAKÇA.....	88
EKLER.....	116

ÖZET

TİCARİ ALACAK RİSKİ YÖNETİMİ VE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE MODELLEME: BİR MODEL ÖNERİSİ

Küreselleşmenin yükselişi ile global ticaretin görünümü değişmiş ve artan ekonomik entegrasyonun bir sonucu olarak kredi piyasasının gelişimi ekonomik büyümenin itici gücü olmuştur. Son yıllarda artan küreselleşme, teknolojik gelişimler, belirsizlik ortamı ve rekabet ile şekillenen yeni dünya düzeni beraberinde kurumların maruz kaldığı riskleri daha öngörülemez hale getirmiştir. Bu nedenle, kredi riski her zamankinden daha önemli hale gelmiş; yaşanan ekonomik şok ve kırılganlıklar kredi riskinin etkin bir şekilde değerlendirilmesini kaçınılmaz bir zorunluluk haline getirmiştir. Firmaların kredi risklerini iyi yönetebilmeleri rekabet güçlerinin artmasını sağlamasının yanında ülke ekonomisinin istikrarına da destek olur.

Likidite ihtiyacının ve sermayeye erişim maliyetinin arttığı bu dönemde ticari alacak kredisi piyasayı destekleyici bir enstrüman olmuştur. Bu bağlamda, çalışmanın amacı özel sektörde faaliyet gösteren bir firmanın ticari ilişki içerisinde olduğu müşterilerin verilerinden ve ekonomik göstergelerden faydalanarak; makine öğrenmesi algoritmaları ile kredi riskini tahmin eden bir model geliştirmek ve literatürdeki bu eksikliği gidermektir. Çalışma ile müşterilerden gelen yeni bir siparişe ait borcun zamanında ödenip ödenmeyeceği sorusuna cevap aranmıştır. Böylelikle, borçlunun ödeme performanslarına göre olası zararın önceden görünür hale gelmesi ile karar vericilerin daha hızlı ve doğru karar almalarına destek olunması hedeflenmiştir. Bu kapsamda, kullanılan makine öğrenmesi algoritmaları içerisinde sınıflandırma tahmin gücü ve doğruluk seviyesi en yüksek olan rastgele orman olmuştur. Modelde etkili en önemli ilk altı değişken sırasıyla müşterinin ortalama vade aşım süresi, toplam ödeme tutarı, ödeme için anlaşılan vade süresi, müşteri ile olan ticari faaliyet süresi, son siparişin üzerinden geçen gün sayısı ve dolar kurudur. Ayrıca, ekonomik verilere bağlı özniteliklerin modelde etkili olduğu görülmüştür. İlerleyen çalışmalar için ürün tipi bazında farklı kredi riski modelleri geliştirilebileceği düşünülmektedir.

Anahtar Kelimeler: Kredi Riski, Makine Öğrenmesi, Rastgele Orman, Makroekonomik Faktörler, Literatür İncelemesi

ABSTRACT

CREDIT RISK MANAGEMENT AND MODELLING WITH MACHINE LEARNING ALGORITHMS: A MODEL SUGGESTION

The changing landscape of global trade due to globalization and increasing economic integration has led to the credit market becoming a key driver of economic growth. The evolving new world order, characterized by globalization, technological advancements, uncertainty, and heightened competition, has made institutional risks more unpredictable. Consequently, the assessment of credit risk has become more crucial than ever. Effective credit risk management not only enhances companies' competitiveness but also bolsters the stability of the national economy.

In the current environment of heightened liquidity needs and increased cost of capital access, trade credit has emerged as a crucial market support mechanism. Therefore, this study aims to utilize customer data and economic indicators, in conjunction with a privately operating company's commercial connections, to create a model that can predict credit risk using machine learning algorithms. The primary objective is to address a gap in the existing literature and provide decision-makers with a tool to assess whether the debt associated with a new customer's order will be paid on time. This approach aims to proactively identify potential losses based on debtors' payment performance and facilitate swift decision-making. Random forest demonstrated the highest classification predictive power and accuracy level among the machine learning algorithms employed. The first six major variables in the model include the average customer overdue period, total payment amount, agreed term for payment, commercial activity period with the customer, the number of days since the last order, and the dollar exchange rate, in that order of importance. Furthermore, it was observed that variables associated with economic data are effective in the model. Further research can focus on developing various credit risk models tailored to specific product types.

Keywords: Credit Risk, Machine Learning, Random Forest, Macroeconomic Factors, Literature Review

KISALTMALAR

AUC	ROC Eğrisi Altındaki Alan
DVM	Destek Vektör Makineleri
EDA	Keşifçi Veri Analizi
ERP	Kurumsal Kaynak Planlaması
ESRB	Avrupa Sistemik Risk Kurulu
EVDS	Elektronik Veri Dağıtım Sistemi
FCRA	Adil Kredi Raporlama Yasası
G20	20 Grubu
GSYİH	Gayri Safi Yurt İçi Hasıla
IIF	Uluslararası Finans Enstitüsü
IMF	Uluslararası Para Fonu
KKB	Kredi Kayıt Bürosu
KNN	K-En Yakın Komşu
LGD	Temerrüt Halinde Kayıp
MDA	Çoklu Ayırma Analiz
MKMV	Moody, Kealhofer, McQuown, Vasice
NACM	Ulusal Kredi Yönetimi Birliği
OECD	Ekonomik İş birliği ve Kalkınma Örgütü
PD	Temerrüt Olasılığı
ROC	Alıcı İşletim Karakteristik Eğrisi
SQL	Yapılandırılmış Sorgu Dili
TCMB	Türkiye Cumhuriyet Merkez Bankası
TÜİK	Türkiye İstatistik Kurumu
WEF	Dünya Ekonomik Forumu
WTO	Dünya Ticaret Örgütü

ŞEKİL LİSTESİ

Şekil 1.1. Ticaret (GSYİH'nin %'si).....	4
Şekil 1.2. Yurtiçi Kredi Stoğu / GSYH (Yıllık, %)......	5
Şekil 1.3. Küresel Ticaret Payları.....	5
Şekil 2.1. Finansal Riskler.....	9
Şekil 2.2. Finansal Araçların Ele Aldığı Başlıca Küresel Riskler.....	17
Şekil 2.3. Ülke Bazlı Şirket Ödeme Yapamama Risk Haritası.....	18
Şekil 2.4. Karşılıksız İşlemi Yapılan Çek ve Protestolu Senetler.....	19
Şekil 3.1. Kredi Riskine İlişkin Uygulamalarda Makine Öğrenimi Kullanımları.....	42
Şekil 3.2. Makine Öğrenmesi Teknikleri.....	42
Şekil 4.1. Model Uygulama Metodolojisi.....	63
Şekil 4.2. Karmaşıklık Matrisi.....	72
Şekil 4.3. Destek Vektör Makineleri Karmaşıklık Matrisi.....	73
Şekil 4.4. K- En Yakın Komşu Karmaşıklık Matrisi.....	73
Şekil 4.5. Rastgele Orman Karmaşıklık Matrisi.....	74
Şekil 4.6. Gradyan Artırma Karmaşıklık Matrisi.....	74
Şekil 4.7. Aşırı Gradyan Artırma Karmaşıklık Matrisi.....	74
Şekil 4.8. ROC Eğrisi ve AUC.....	77
Şekil 4.9. Destek Vektör Makineleri ROC Eğrisi.....	77
Şekil 4.10. K- En Yakın Komşu ROC Eğrisi.....	78
Şekil 4.11. Rastgele Orman ROC Eğrisi.....	78
Şekil 4.12. Gradyan Artırma ROC Eğrisi.....	78
Şekil 4.13. Aşırı Gradyan Artırma ROC Eğrisi.....	79
Şekil 4.14. En İyi Model (Optimize Edilmiş Rastgele Orman) ROC Eğrisi.....	81
Şekil 4.15. Modellere Ait Doğruluk Karşılaştırması.....	82
Şekil 4.16. Modele En Etkili 35 Değişken.....	83

TABLO LİSTESİ

Tablo 3.1. Beklenen Kayıp Değişkenleri.....	24
Tablo 3.2. Kredi Riskinin Gelişiminde Değerlendirme Yaklaşım ve Yöntemleri.....	25
Tablo 3.3. Geleneksel Yöntemler Yurt Dışı Literatür Taraması.....	32
Tablo 3.4. Geleneksel Yöntemler Yurt İçi Literatür Taraması.....	39
Tablo 3.5. Makine Öğrenmesi Yöntemleri Yurt Dışı Literatür Taraması.....	50
Tablo 3.6. Makine Öğrenmesi Yöntemleri Yurt İçi Literatür Taraması.....	57
Tablo 4.1. Model Karmaşıklık Matrisi Değerleri ve Tip I ve Tip II Hata.....	76
Tablo 4.2. AUC Değerleri.....	79
Tablo 4.3. Model Performans Ölçüm Metrikleri.....	80
Tablo 4.4. En İyi Model Performans Ölçüm Metrikleri.....	81
Tablo 4.5. En İyi Model Tip I ve Tip II Hata, AUC ve Doğruluk Metrikleri.....	81

GİRİŞ

Kredi kavramı, ekonomik ilişkileri şekillendiren ve ticaretin gelişmesinde kritik öneme sahip olan bir araçtır. Geçmiş antik dönemlere kadar uzanan kredi, günümüzde dünya çapında artan ticaret hacminin etkisiyle finansal düzenin temel yapı taşlarından biri haline gelmiştir. Ekonomik büyümenin sağlanması, işletmelerin gelişimi ve bireylerin ihtiyaç ve isteklerinin karşılanmasında önemli bir unsurdur. Özellikle, finansal olmayan kurumlar tarafından sağlanan ticari alacak kredisi firmaların bilançolarında önemli bir hacme sahiptir.

Tüm paydaşların finansal hedeflerine ulaşabilmelerinde önemli bir rol oynadığı için zamanla kredi kullanımı artmış ve büyüyen borç hacmi kredi riskini ön plana çıkarmıştır. Yaşanan küresel finansal krizler ve ekonomik belirsizlikler kredi riskinin önemini daha da vurgulamıştır. Bu dönemlerde alternatif bir finansman aracı olarak öne çıkan ticari alacak kredisinin, tedarik zinciri boyunca ticaretin devamlılığı ve ekonomik döngünün sağlanmasındaki payı yadsınamaz. Ancak, kredilerin geri ödenmemesi, ödemelerde gecikme yaşanması ya da borçluların iflas etmesi halinde alacakların tahsilatında sorunlar yaşanır ve likidite olumsuz etkilenir.

Bu olumsuz etkilerin yansımalarını daha iyi yönetebilmek için kredi riskinin değerlendirme yöntemleri zamanla gelişme göstermiştir. Özellikle, 21. yüzyılın başlarından itibaren ivme kazanan makine öğrenmesindeki teknolojik gelişmeler ve hızlanmalar, bu yöntemlerin geleneksel istatistiki yöntemlerden, yeni veya hibrit modellere geçişini sağlamıştır. Büyük miktarda veriyi yönetebilen bu algoritmalar istatistiki yöntemlerin kısıtlamalarını aşmak için çeşitli veri setlerinde gelişmiş öğrenme ve tahmin yeteneği ile ön plana çıkmaktadır.

Bu çalışma, kredi riskinin tarihçesinden günümüzdeki önemi ve uygulamalarına kadar geniş bir perspektif sunmayı amaçlamaktadır. Enflasyonist ortam ve kredi maliyetine erişimin zorlaştığı ve bu dönemde; finansal olmayan işletmelerin, müşteri kredi risklerini ticari ilişkilerinden doğan bilgiler ve ekonomik göstergelerden faydalanarak değerlendirebilecekleri bir model önerisi sunulmuştur. Pandemi döneminde belirginleşen hızlı değişikliklerin model sonuçlarına yansıdığı gerçek zamanlı kredi riski değerlendirme ihtiyacını karşılayacak şekilde literatürde ağırlıklı olarak kullanılan mali bilgiler yerine müşterinin satın alma tercihleri ve geç ödeme davranışları incelenmiş; dış ekonomik etkilerin bu kararlar üzerindeki etkisini yansıtacak şekilde ekonomik veriler dahil edilmiştir. Ayrıca, müşterinin finansal yetkinliğinin yanında operasyonel süreçlerdeki yetkinliklerini değerlendiren ve mevcut iş birliğine göre hem subjektif hem verilere dayalı bir segmentasyon değişkeni de modele dahil edilmiştir. Çalışma

konusu itibariyle literatürdeki boşluğu doldurmayı amaçlamakla birlikte kullandığı bazı değişkenler ile de ayrılmaktadır.

Literatürde kredi riski değerlendirme yöntemlerinin doğruluk başarısı ve tahmin gücü performanslarının arttırılması amacıyla kullanılan tekniklerde hala geliştirmeler yapılmakta ve yenileri de doğmaktadır. Dolayısıyla, kredi riski literatüründeki çalışma sonuçlarında tarihi gelişmelere bağlı olarak ağırlıklı olabilecek sayıda başarı gösteren temel yöntemler olsa da en iyi olarak nitelendirilebilecek tek bir yöntem bulunmamaktadır. Özellikle veri setinin özellikleri ve doğasına bağlı olarak da değişebilen bu durum çalışmaların başarılarında veri kalitesinin de oldukça etkili olduğunu göstermektedir. Bu bağlamda, çalışmada keşifçi veri analizi, veri ön işleme ve özellik mühendisliği aşamalarına yer verilmiştir. Python'da denetimli makine öğrenmesi algoritmaları kullanılarak torbalama, yükseltme ve istatistik temelli genel model performanslarının da karşılaştırılmasına olanak tanır şekilde hazırlanan çalışmanın sonraki araştırmalar için fayda sağlayacağı ve özel sektöre katkısının olacağına inanılmaktadır.

Çalışmanın ilk bölümünde kredi, ikinci bölümünde kredi riski ve üçüncü bölümünde kredi riski değerlendirme yöntemleri ele alınacaktır. Çalışma kapsamında, istatistiksel yöntemlerden doğrusal ayırma analizi, lojistik regresyon ve probit yöntemleri incelenirken; makine öğrenmesi algoritmalarından destek vektör makineleri, k-en yakın komşu algoritması, rastgele orman, gradyan artırma ve aşırı gradyan artırma yöntemleri ele alınacaktır. Sonraki bölümlerde, veri seti belirtilen makine öğrenmesi yöntemlerini uygulamaya hazır hale getirilip çıkan sonuçlar değerlendirilecektir.

BÖLÜM 1: KREDİ

1.1. Kredi

Kredi, gelecekteki bir ödeme sözü karşılığında, borç veren (alacaklılar, kredi verenler) tarafından borç alana (borçlular, kredi alanlar) para, mal, hizmet veya menkul kıymet sağlanan bir finansman işlemi olarak tanımlanabilir (Joseph, 2013). Mal ve hizmet alışverişleri, üretim süreçleri ve tüm modern finansal hizmet ekonomilerinde önemli bir rol oynamaktadır (Stals,1998). Doğası gereği kredi döngüsünde yer alan bir paydaşın; birey, tüzel kişi ya da devlet kurumu olması fark etmeksizin satın alma gücünü arttırmaktadır (Stals, 1998). Bu nedenle, ekonomik büyümenin ivmesini sağlayan ticari fırsatlar için parasal araçların temininde merkezi bir rol üstlenmektedir (Snaije, 2017). Kredi piyasalarının sağladığı bu kaynakların tahsisinin bozulması çeşitli makroekonomik ve mikroekonomik sonuçlar doğurabilmektedir (Buera vd., 2015). Örneğin, işsizlik artabilir (Buera vd., 2015) ve tedarik zincirlerinde likidite şokları yaşanabilir (Love ve Zaidi, 2010). Artan belirsizlik ortamları ile ekonomik aktiviteyi yavaşlatabilir ve hatta resesyona dahi sebep olabilir. Beraberinde bankaların kredi kararları da bu belirsizliklerin artmasına sebep olabilir (Grimme ve Henzel, 2024). Bu nedenlerle, modern ekonomilerin kredisiz çalışması oldukça zordur (Stals, 1998).

Ekonomilerde kredi piyasasının gelişmişliği ne kadar artarsa demokratik süreçler bir o kadar desteklenir ve yönetim çerçevesine duyulan güven artar (Snaije, 2017). Kredi bağımlılığı yüksek olan ülkelerde hükümetlerin finansal gelişimdeki yeteneklerini artırıcı politikalar uygulaması kredi piyasasının gelişiminde önemli bir rol oynamaktadır (Becerra vd., 2012). Özellikle, daha az gelişmiş ülkelerde finansal sistemin gelişmesiyle kurumlara aktarılan krediler gelişimi sağlar (Becerra vd., 2012). Böylelikle, finansal yönetim ve kurumların gelişimi ekonomik büyümeye katkı sağlar (Gulcemal, 2021).

Küreselleşmenin yükselişi, gelişmekte olan ekonomiler, yüksek teknolojik ürünler ve üretim süreçlerinin parçalanması ile global ticaretin görünüşü son birkaç on yılda önemli değişimler yaşamıştır (Riad vd., 2012). Artan ekonomik entegrasyonun bir sonucu olarak (Batten vd., 2023), kredi piyasası ekonomik büyümenin itici gücü olmuştur (Heinemann ve Tanz, 2008). Küresel Gayri Safi Yurtiçi Hasıla (GSYİH)'dan daha hızlı büyüyen global ticaret (Hodgson, 2006); finansal kriz, artan ekonomik politika belirsizlikleri (Armeliş vd., 2014) ve borç verme standartlarının daha kısıtlayıcı bir hal alması ile yavaşlamıştır (Constantinescu vd., 2020) (bkz. Şekil 1.1.). Küresel ekonomi üzerinde ciddi bir etki yaratan COVID-19 salgınında

(McKibbin ve Fernando, 2020) tedarik zincirlerinde aksamalar meydana gelmiş ve arz ve talep dengeleri bozulmuştur (Kalemlı-Ozcan vd., 2020). Artan ticaret maliyetleri (Vo ve Tran., 2021) ise firmalar için finansal baskıya sebep olmuştur. (Kalemlı-Ozcan vd., 2020) Dolayısıyla, operasyonların sürdürülebilmesi ve iş sürekliliğinin sağlanması için kaynak ihtiyacı artmıştır (Baker vd., 2020; Ivanov ve Dolgui, 2020). Buna karşın, belirsizlik ortamı, bankaların kredilerde daha temkinli bir yaklaşım sergilemelerine sebep olmuş ve dış kaynağa erişim daha maliyetli bir hale gelmiştir (Ayyagari vd., 2010; Xie ve Tian, 2023). Bu nedenle, hükümetler, likiditesi zayıf olan firmalar için krediye erişimlerini kolaylaştırıcı programlar oluşturmuştur (Zhang ve Sogn-Grundvåg, 2022). Yaşanan finansal strese rağmen, küresel ticaret ilişkileri dayanıklılık göstererek ilerleyen süreçte toparlanmaya başlamıştır (Le Moigne, M., 2020). Son birkaç yılda yaşanan jeopolitik riskler (The World Trade Organization, 2023), emtia şokları, enflasyonist ortam ve sıkılaştıran kredi koşulları, ticaret, yatırım ve faaliyet maliyetlerini etkilemeye devam etmektedir (Gourinchas, 2023). Bu kaynak ihtiyacına bağlı olarak ticaretin kredi ile olan yakın ilişkisi devam edecektir.


Şekil 1.1. Ticaret (GSYİH'nin %'si),



Kaynak: The World Bank (2024)

Özellikle çoğu gelişmekte olan ekonomide 2000'li yılların başı itibariyle kredi derinleşmesi yaşanmış ve ekonomik faaliyetler için kredi piyasası daha önemli bir hale gelmiştir (Büyükbasaran vd., 2022) (bkz. Şekil 1.2.).


Şekil 1.2. Yurtiçi Kredi Stoğu / GSYH (Yıllık, %)



Kaynak: Büyükbaşaran vd. (2022)

OECD'nin 50 yıllık projeksiyonuna göre küresel ticaretin, yıllık %3,5 büyüme beklentisi (1990-2007 dönemine göre %6,9) ile coğrafi merkezinin gelişmekte olan piyasalara doğru yönelmeye devam edeceği yönündeki tahmini (Johansson ve Olaberria, 2014) bu önemin artacağını göstermektedir. Buna göre Çin, Hindistan ve diğer Asya ülkelerinin payının artması beklenmektedir (Johansson ve Olaberria, 2014) (bkz. Şekil 1.3.). WTO'da (Dünya Ticaret Örgütü) 2050 yılı için benzer şekilde ticaretin ekonomik büyümeden (GSYİH) daha hızlı büyüyeceğini ve yıllık olarak %3,09 seviyesi ile gerçekleşeceğini tahmin etmektedir (Bekkers vd., 2023). Bölgesel liberalizasyon ve teknoloji ile ticaret maliyetlerinin düşeceği öngörülse de uygulanabilecek ara girdi tarifeleri maliyetlerin artmasına sebep olabilir ve rekabet zorlaşabilir.

Şekil 1.3. Küresel Ticaret Payları



Kaynak: Johansson ve Olaberria (2014)

Bu noktada, işletmelerin ticaretin döngüsünü hızlandıran ve işletmelerin likidite ihtiyacını karşılayan ticari alacak kredisi ticaretin gelişimini destekleyecektir.

1.2. Ticari Alacak Kredisi

Ticari alacak kredisi, maliyetlerin finansal kuruluşlarda olduğu gibi ayrıca belirtilmediği ancak ürünlerin liste fiyatına ya da nakit iskontosuna yansıtıldığı bir kredidir (Schwartz, 1974). Mal ve hizmet sağlayan finansal olmayan kurumsal firmalar tarafından sunulduğu için (Paul ve Boden, 2014); tedarikçi finansmanı, işletme kredisi, kredili satış ya da firmalar arası kredi olarak da anılmaktadır (Mian ve Smith, 1992; Ng vd., 1999; Kong vd., 2016). Modern kurumsal finansmana göre de alacaklara yapılan yatırımdır (Paul vd., 2018) ve küresel tedarik zincirleri ile giderek daha belirgin hale gelmiştir (Boissay vd., 2020). Bu nedenle, büyüme için önemli bir faktör niteliği taşır (Abdulla vd., 2017; Yang ve Birge 2018; Chen ve 2019; Bertrand ve Murro, 2022; Gofman ve Wu, 2022).

Ticari alacak kredisi, alternatif bir finansman yöntemi olarak kullanılmasının yanında (Machokoto vd., 2022) global ticaretin de önemli bir kısmını oluşturmaktadır (Klapper vd., 2012). Modern ekonomiler için önemli bir kaynak sağlayıcıdır (Rajan ve Zingales, 1995). Gelişmekte olan ve gelişmiş ülkelerin şirket bilançolarında önemli bir yeri vardır. Amerika Birleşik Devletleri firmalarının yaklaşık %80'inin ürün satışlarını ticari alacak kredisi ile sunduğu tahmin edilmektedir (Tirole, 2006). Birleşik Krallık'ta firmalar arası işlemlerin %80'inden fazlası krediyle yapılmaktadır (Wilson ve Summers, 2002). Bu oran Fransa'da ülkenin GSYİH'nin yarısından fazlasıdır (Dornel vd., 2023). Bazı Avrupa ülkelerinin ortalamasına göre alacak hesapları toplam varlıkların %30'u civarındadır (McGuinness vd., 2018): İspanya %39,28 (García-Teruel ve Martínez-Solano, 2010). Güney Afrika'da ise benzer şekilde %32 seviyesindedir (Kwenda ve Holden, 2014).

Ticari alacak kredisi, özellikle gelişmekte olan ekonomilerde finansal sistemdeki kısıtlamalar nedeniyle etkili bir finansman aracıdır (Brasch, 1972). Örneğin, Çin özel sektör firmalarının krediye erişimleri yerel yönetim müdahaleleri ve devlet mülkiyetli işletmeler nedeniyle daha kısıtlıdır (Lin, 2003; Jiang ve Kim, 2015; Huang vd., 2019). Bu nedenle, ülkenin ekonomik büyümesi ve faaliyetlerinin sürdürülebilirliğinde ticari alacak kredisinin önemli bir etkisi olmuştur (Huang vd., 2019).

Firmalar kaynak tercihlerini parasal ve mali koşullar başta olmak üzere ekonomik çevreyi dikkate alarak araştırırlar (Bialek-Jaworska ve Nehrebecka, 2016). Bu kaynaklar iş

kurmanın yanında sürdürülebilirliğini sağlamak ve gelişmek için de gereklidir (Białek-Jaworska ve Nehrebecka, 2016). Bu noktada, ticari alacak kredisi şirket iç kaynaklarının yeterli olmadığı (Myers ve Majluf, 1984), bilgi asimetrisinin, finansal kısıtlamaların ve likidite şoklarının olduğu durumlarda önemli bir rol oynamaktadır (Burkart ve Ellingsen, 2004; Molina ve Preve, 2012; Chen vd., 2017; Hasan ve Habib, 2019). Firmalar tarafından resesyon veya finansal kriz dönemlerinde belirsizliğin etkilerinin artmasıyla (Grimme ve Henzel, 2024) yeterli likidite ve ödeme gücünün sağlanması için (Paul ve Boden, 2014) banka kredisinin yerine tercih edilmektedir (Bastos ve Pindado, 2013). 2008-2009 mali krizi (Coulibaly vd., 2013; Ferrando ve Mulier, 2013) ve pandemi döneminin ilk evresinde banka kredisinin ikamesi olarak işletmelere yardımcı olmuştur (Al-Hadi ve Al-Abri, 2021). Finansal piyasaların olumsuz bir seyir izlediği ortamda talep tarafı için oluşan likidite pozisyonunu koruma isteği ve borçlanma maliyetlerinin yüksek olması ticari kredi kullanımını teşvik etmektedir. Sürecin sağladığı operasyonel esneklik ile talep dalgalanmalarına karşı arz tarafında da avantaj sağlamaktadır. Ancak, Türkiye’deki ticari alacak kredi koşullarının, küresel likiditenin azalması ve bankalardan finansman sağlamanın zorlaşması sonrasında kötüleştiğini ve yaşanan şokun etkisiyle tüm tedarik zincirinin etkilendiğini de belirtmek gerekir (Kadırgan ve Özlü, 2023).

Ticari alacak kredisi kullanımı talep tarafı için paranın zaman değerinden fayda sağlayabilmesi nedeniyle bir tercih sebebi olur (Schwartz, 1974). Ödemenin şartları taraflar arasında yapılan sözleşmeye bağlı olarak değişebilmektedir. Tek parçalı sözleşme faizi olmayan bir kredi niteliği taşımakla birlikte belirlenen sürede ödeme beklenir ve erken ödeme için herhangi bir teşvik ya da iskonto uygulanmaz (Goyal, 1985). İki parçalı sözleşmede ise erken ödeme uygulaması ile indirim dönemi sonrasında gecikme için ek ödeme talep edilebilir (Ng vd., 1999). Bu seçenekler, ürün veya hizmetin teslimatından sonra ödemenin yapılmasına ya da ötelenmesine imkân tanır (Fitzpatrick ve Lien, 2013). Ödeme vadesi belirli olduğundan dolayı firma kısa dönem nakit akışını daha verimli yönetebilir; bu süreçte elde ettiği satış gelirlerini değerlendirerek kazanç sağlayabilir (Huang ve Hsu, 2008) veya ürün veya hizmet satın alabilir. Borcun erken ödenmesi halinde ise hak edilecek iskonto ile ek bir finansal getiri elde edilebilir. (Wilson ve Summers, 2002).

İkincil tercih sebebi olarak kredi tayinlaması belirtilebilir (Biais ve Gollier, 1997). Banka kredisine erişimde zorluk çeken alıcı tarafın işletme sermayesi ihtiyacı karşılanarak (Chen ve Kieschnick, 2018) büyümesine olanak sağlanmış olur (Long vd., 1993). Ürün ve hizmet kalitesinin kıyaslanabildiği varsayıldığında kredi talep eden taraf en iyi ödeme

koşullarını veya en uzun ödeme süresini sunan tedarikçiyi seçmektedir (Shipley ve Davies, 1991).

Tedarikçi taraf için satış büyümesinin pozitif yönde etkilenmesi (Yazdanfar ve Öhman, 2015) ve pazarını genişletmesine olanak tanınması (Rajan ve Zingales, 1995) ticari alacak kredisinin kullandırımı için önemli bir faktördür. Böylelikle, daha uzun vadeli ticari ilişkiler kurulabilir, müşteri sadakati sağlanabilir (Summers ve Wilson, 2003) ya da yeni müşteri kazanımları olabilir (Machokoto vd., 2022). Bununla birlikte ticari alacak kredisi fiyat esnekliği de sağlar (Chen vd., 2024). Böylelikle, firmaların karlılığını artırma fırsatı olur (Chod vd., 2019). Ancak, koşullar sıkılaştığında alınacak sipariş miktarında azalma görülebilir (Seifert vd., 2013).

Firmaların değişimlere daha hızlı uyum sağlamaları ve artan rekabet ortamında ayakta kalabilmeleri için dijital teknoloji yeteneklerini de güçlendirmeleri gerekir (Vial, 2021). Bunu sağlayan firmalar, işletme verimliliği ve şeffaflığın artması ile kredi itibarlarını arttırmaktadırlar (Zhang vd., 2023). Teknoloji ile gelişen finansal sistemlerin dış kaynaklardan sağlanacak finansmanı daha fazla ihtiyacı olan sektörlerle yönlendirmesi ile uzmanlaşmayı arttırabilir; (Rajan ve Zingales, 1998; Beck, 2002) ticareti ve refahı olumlu yönde etkileyebilir (Johansson ve Olaberría, 2014).

Tüm bu hususlar değerlendirildiğinde finans ve ticari işlemlerin en önemli risklerinden birinin kredi riski olduğunu belirtmek yanlış olmayacaktır (Spuchl'akova ve Cug, 2015).


BÖLÜM 2: KREDİ RİSKİ

2.1. Kredi Riskinin Tanımı

Kredi riski, Avrupa Sistemik Risk Kurulu (European Systemic Risk Board-ESRB) (2004)'e göre taraflar arasındaki anlaşmadan doğan yükümlülüklerin yerine getirilmemesi sebebiyle ortaya çıkan zarar olasılığı olarak tanımlanmaktadır. Tahviller, kısa vadeli borçlanma senetleri ve türev ürünler gibi diğer varlık türleri ile bilanço dışı kredi tahsis ya da limit taahhütlerinde de kredi riski bulunmaktadır.

Finansal piyasaların bilinen en eski risk türü olan kredi riski (Caouette vd., 1998) piyasa, likidite ve operasyonel riskler olarak sınıflandırılan temel finansal risklerden biridir (Jilek, 2000; Bartošová, 2005, akt. Valášková vd., 2014) (bkz. Şekil 2.1). Kredi riski kavramı, temerrüt riski, iflas riski, derece düşüş riski, uzlaşma riski (İltaş, 2021), performans riski ve karşı taraf riski olarak da adlandırılmaktadır (Wójcicka-Wójtowicz, 2018).

Şekil 2.1. Finansal Riskler



Kredi riski; artan rekabet, değişen müşteri beklentileri, talep ve arzadaki değişimler, tedarik zincirindeki aksamalar, yeni teknolojiler, jeopolitik riskler, döviz kuru ve faiz politikaları, kârlılık, fiyat artışları, hükümet politikaları, yasal düzenlemeler, finansal kayıplar, likidite, aşırı borçlanma, enflasyon, işsizlik, ekonomik büyüme ve üretim, tedarik zinciri, iklim değişikliği ve belirsizlik ortamı gibi birçok sebepten etkilenebilir ve benzer şekilde bu değişkenleri de etkileyebilir.

Kredi riskinin en büyük kaynağını borçlanmalar oluşturmaktadır (Caouette vd., 1998). Borcun geri ödenme durumu her zaman bir belirsizlik unsurunu beraberinde taşır. Borçlu tarafın mali sorunlar nedeniyle ödeme yapamayacak durumda olması, ödeme yapmak istememesi ya da zamanında ödeme yapmamasından kaynaklanabilir (Eke ve Toprak, 2020). Bu bağlamda,

kredi riskinin temel mantığının Antik Mısır zamanından beri değişmediği söylenebilir (Caouette vd., 1998).

2.2. Kredi Riskinin Tarihçesi

Antik zamanlara ait ticari kayıtlar, kredi riskinin ticaretin başlangıcından itibaren önemli bir gerçeklik olduğunu göstermektedir. Örneğin, Mezopotamya’da yaklaşık 4000 yıl öncesine dayanan Hammurabi Kanunları ticaretin erken dönemlerindeki kredi uygulamalarının ilk yazılı örneklerini sunmaktadır (Gelpi vd., 2000). Bu sistem, farklı kredi türlerini, faiz oranlarını, geri ödeme şekillerini, tahsilatı, garantilerini ve yasal dayanaklarını tanımlamaktadır (Gelpi vd., 2000). Ayrıca, borcun geri ödenmemesinin bir suç olduğunu; hırsızlık ve yolsuzluk ile eş ceza değerine sahip olması gerektiğini belirtmiştir (Brown, 2004).

Kredi riskinden korunmak için Roma döneminde sözleşmeler yapılmakta ve teminat alınmaktaydı (İldız, 2009). Çok gelişmiş bir finansal sistemi olduğu anlaşılan Antik Roma’nın kanunlarında faiz oranları ve kâr düzenlemelerinin oldukça önem arz ettiği görülmektedir (Altınay ve Akıncı, 2018). Antik dönem Roma ve Mezopotamya’daki bu kurallar ile kredi risk yönetimine ait ilk girişimler görülmektedir (Colquitt, 2007). 18. ve 19. yüzyıllarda endüstriyel devrim ile artan sermaye ihtiyacı, teknolojik gelişmeler ve modern bankacılık sistemi, kredi riskinin değerlendirilmesi ve raporlanmasında ilk adımların atılmasını sağlamıştır.

18. yüzyılda, bireyler ve işletmeler, borç verenlerden kredi alabilmek için saygın tanıdıklarından karakterlerine kefil olmalarını istemekteydiler (Hiller ve Jones, 2022). 18. yüzyılın ikinci yarısına gelindiğinde kişisel tanışıklık ve itibar temelli ölçümlerin kredi ilişkilerinin yönetiminde yeterli olmayışı yeni yaptırımların getirilmesini gerektirmişti (Lemercier ve Zalc, 2012). Büyük ölçekli ticari işlemlerin yanında günlük hayatta da sıklıkla kullanılan kambiyo senetlerinin ciro edilebilirliğinin tehlikeli hale gelmesi ve çeşitli dolandırıcılık işlemlerinde kullanılmasından dolayı “kötü kredi” tabiri ile özleşmişti (Lemercier ve Zalc, 2012). Kambiyo senetleri, kredi kullanımının yaygınlaşmasını sağlarken, ticaretin, resmi ve hukuka dayalı kurumlara geçişinde önemli bir adım atılmış oldu.

1837 yılında spekülatif borç verme uygulamaları nedeniyle yaşanan mali kriz, kredi problemlerinin çözülmesi gerektiğini aksi takdirde güçlü ancak likit olmayan firmaların yok olacağını göstermişti (Berghoff, 2009). 1841 yılında iflas yasasının çıkmasıyla itibara dayalı borç vermenin riski daha da artmıştı (Hiller ve Jones, 2022). Bu gelişmeler doğrultusunda aynı yıl Ticaret Ajansı (The Mercantile Agency), ticari bir raporlama firması olarak New York’ta

faaliyete geçti (Jentzsch, 2007). Kredi derecelendirme işi sistematik olarak diğer firmaların kredibiliteleri hakkında bilgi toplama ve işleme usulü ile başlamış oldu (Carruthers, 2013) ve bankacılar arasındaki dedikodu ve ilişki kredilerinin yerini aldı (Jentzsch, 2007). Artık, kredi talebinde bulunanlar hakkında bilgi edinme ve inceleme için üçüncü bir taraf vardı (Cohen ve Carruthers, 2014).

Ticaret ajansının ardından, 1849 yılında diğer ajanslar açılmaya başladı. Bankacılık kredisinin değerlendirilmesine yönelik işlem ve prosedürlerde kullanılan ve daha sonraları geliştirilmeye devam edecek olan karakter, kapital ve kapasite açılımlı '3C' unsurlarının kullanımını açıklayan ilk taraf Ticaret Ajansı olmuştu (Rötheli, 2013). İlk kredi raporlama kuruluşları bilinmeyen borçlular hakkında topladıkları bilgilerin merkezileştirilmesini sağlamış ve ticari kredi verenlere yardımcı olmuşlardı (Lauer, 2022).

1880 ve 1890'lı yıllara gelindiğinde üretici, toptan satış ve bankalarda, kredi onayları ve tahsilatların yapılması için kredi görevlileri çalışmaya başlamıştı (Smith, 2010). Ancak, finansal kurum ya da posta yoluyla işlem yapan firmalardaki kredi analistleri yargıya dayalı kararlar alıyordu (Sabato, 2010). 1896 yılında bankalarda çalışan kredi uzmanlarının yetiştirilmesi ve gerekli örgütlenmenin sağlanması için Ulusal Kredi Yönetimi Birliği (NACM) kuruldu (Rötheli, 2013). Bu kurum tarafından ajanslara yönelik profesyonel ilk eleştiri yapıldı ve kayıplara ilişkin sorumluluklarından kurtulmaları için harekete geçildi (Cohen ve Carruthers, 2014).

19. yüzyılın sonlarında krediye olan tutum değişmeye başlamıştı. İşletmeler ve tüketiciler aşırı kredi kullanmıştı (Smith, 2010). Bu durum, kredi verme uygulama ve politikalarını etkiledi. Özellikle, endüstrileşme ve ticaretin gelişmesiyle birlikte, krediye olan talep artmış; sanayi devrimi ve ekonomik büyüme, işletmelerin ve bireylerin daha fazla yatırım yapma ve büyüme fırsatları aramasına neden olmuştu. Bunun sonucunda, kredi sağlama işlevi daha belirgin hale gelmiş ve kredi verenlerin risk yönetme ihtiyacını arttırmıştı.

Kredilerin kullanımının yaygınlaşmasıyla birlikte işlenmesi gereken veri hacminin de artması yerel ajanslardan daha merkezi bir organizasyon ihtiyacı doğurmuştu (OppU, 2023). 1899 yılında, tüketici kredi raporlamasını yapan ilk firma olan Perakende Kredi Şirketi kuruldu ve bu sektöre öncülük ederek bireylerin sosyal ve politik bilgileriyle kredi dosyalarını oluşturdu (Hiller ve Jones, 2022). 1907 yılındaki borsa çöküşü ile borç verenler ve yatırımcıların daha fazla risk bilgisine ihtiyacı olduğu belirginleşmişti. Böylelikle, dış kredi derecelendirmeleri ilk kez Moody's tarafından 1909 yılında sunuldu (Kumar ve Bhattacharya, 2006; Angelini vd., 2008). Bu sayede, şirketlerin mülkiyeti ve yönetimi hakkındaki bilgilerin yanında menkul

kıymetlerin analizi de yer aldı (Kumar ve Bhattacharya, 2006). Ancak, tahvil yatırımcılarına sağlanan bu bilgiler çoğunlukla geçer performanslı olacak şekildeydi ve kaba bir derecelendirme sistemine sahipti (Angelini vd., 2008). 20. yüzyıla gelindiğinde küreselleşme ve teknoloji alanındaki ilerlemenin finans dünyasına yansısıyla kredi risk değerlendirmelerine olan ilgi artmıştı.

1930'lu yıllarda kredi kararlarındaki tutarsızlıkların önüne geçebilmek için postayla sipariş, banka ve finans şirketlerinden bazıları kredi skortlama yöntemini kullanmaya başladılar (Bilginci vd., 2019). 1932 yılında finansal kredi riskinin ilk değerlendirilmesi J. FitzPatrick'in risk modellemesi ile gerçekleşti (Chen vd., 2016). Başarılı olan firmaları diğerlerinden ayırt edebilmek için finansal bilgilerden oluşan 13 oranı karşılaştırdı (FitzPatrick, 1932). Bu sırada, 2. Dünya Savaşı'nın başlamasıyla tüm kredi veren kurum ve işletmeler kredi uzmanlarının askere gitmesiyle zorluk yaşamaya başlamışlardı (Thomas vd., 2017). Bu durum uzmanlar tarafından kullanılan analizlerin kurallar haline getirilmesi ve uzman olmayanlar tarafından uygulanmasını sağladı (Thomas vd., 2017). Yaşanan bu süreç uzman sistemlerin ilk örnekleri olmuştur (Thomas vd., 2017). Finansal piyasalardaki çeşitlilik ve gelişim 1960 ve 1970'li yıllarda modern finans alanındaki akademik çalışmaları geliştirdi (Caouette vd., 2011).

1956 yılında Fair, Isaac and Company (FICO), perakendede kredi puanlama hizmetlerini sunmak için kuruldu (Óskarsdóttir vd., 2019). 1960'lı yıllarda, kurumsal finans literatüründe zamanla '5C'¹ olarak gelişen tüketici kredi riski değerlendirme sistemine ait terimler oluştu (Smith, 1964). İflas yasasından 100 yıl sonra 1941 yılında David Durand'ın 37 firma tarafından verilen krediler arasında başvuru sahibinin özelliklerine göre, iyi ve kötü ayırımını yapan çalışması ile kredi skortlama tekniklerinin ilk önemli adımı atıldı (Durand, 1941). 1960'lı yıllara gelindiğinde sosyal ve politik bilgi kayıtlarına dayanan kredi kayıtları sayısallaştırılmak istendi (Sabato, 2010). Kuruluşundan iki yıl sonra 1958 yılında, FICO'nun bilgisayar destekli kredi skortlama sistemlerini geliştirmesiyle bir dönüm noktası yaşandı (McCorkell, 2002). Aynı yıl, FICO finansal kuruluşlardan birine ilk kez kredi skortlama sisteminin satışını yaptı (Bumacov vd., 2017). 1964 yılına gelindiğinde bir finansal kuruluşun kredi başvurularının sisteme girildiği ve gerekli politika kriterleri sağlandığında otomatik olarak puanlanarak 24 saat içerisinde onaylandığı noktaya gelinmişti (Bumacov vd., 2017). 1960'lı yılların sonundaysa kredi kartlarının sayısındaki artışın kredi puanlamalarını ekonomik ve iş gücü anlamında zorlaması bu sürece katkı sağladı (Thomas, 2000).

¹ (1) Karakter, (2) Kapasite (3-4) Sermaye ve Teminat (5) Koşullar

1966 yılında William H. Beaver tarafından önceki çalışmalar geliştirilerek mali tablo verilerindeki finansal oranlar ayrı ayrı kullanılarak oluşturulan tek değişkenli ilk modern istatistiksel model iflas tahmini için kullanıldı (Beaver, 1966). İflas tahmininin olabildiğince erken yapılması ilgili taraflar için bir uyarı niteliği taşımış ve kayıpların azaltılmasını sağlamıştır (Deakin, 1972). Bu alana odaklanan Edward I. Altman, 1968 yılında Beaver'ın çalışmasından farklı olarak finansal oranları girdi olarak kullandı ve firmaların iflas durumunu klasik çoklu ayırma analiz tekniği (MDA) ile sınıflandırdı (Altman, 1968). Oldukça bilinen bu çalışma ilk operasyonel skorlama modeli olmuştur (Abdou ve Pointon, 2011) ve çalışma ile finansal oranların doğrusal kombinasyonu olan Z skoru modeli önerilmiştir². Bu çalışmalar, erken dönem amprik yaklaşımın öncüleri olarak literatürde yerini almıştır (Atiya, 2001).

1970 yılında Adil Kredi Raporlama Yasası (FCRA) kabul edilmiş; büyük kuruluşlar tarafından potansiyel ve mevcut müşterileri ile kredi başvuru sahiplerinin risk düzeylerini hızlı ve doğru bir şekilde değerlendirmek için kredi puanlaması kullanılmıştır (Sabato, 2010). 1972 yılında David Sparks, karar ağaçları modeli ile kredi puanlama kullanımını geliştirdi (Bielecki ve Rutkowski, 2004). Bu dönemde piyasa, politik ve teknolojik baskılarla şekillenen kredi raporlama endüstrisi, günümüz kredi raporlama firmalarının şekillenmesinde önemli bir rol oynamıştır (Furletti, 2002).

1970'li yıllarda yaşanan petrol krizi ve yüksek enflasyon sorunları birçok ülkenin borçlanma maliyetlerini arttırmış ve kredi piyasalarında belirsizliğe neden olmuştu. Bu durum, uluslararası kredi kuruluşlarına başvurmak durumunda kalan ülkelere, Uluslararası Para Fonu (IMF) ve Dünya Bankası tarafından kredi verme ve ekonomik yardım sağlama faaliyetlerini önemli ölçüde arttırdı. Paralelinde, küresel ölçekte artan kredi riskini daha etkin yönetebilmek için daha sofistike yöntemlere olan ihtiyaç da artmıştı. Bu dönemde risk modellerinde belirsizlik ve tarihsel açıdan değerlemelerde en optimal karar alma yöntemleri daha karmaşık bir hale gelmiştir (Merton, 1994). 1974 yılında, kredi riskinin en yaygın kullanılan yöntemlerinden Merton modeli, opsiyon fiyatlaması için önerildi (Vašanič ve Cisko, 2012, akt. Valášková ve Klieštk, 2014). Model, temerrüt riskini firmanın sermaye yapısının çeşitli bileşenleri ile ilişkilendirmektedir (Kavcıoğlu, 2011) ve ilk yapısal model olarak değerlendirilmektedir (Adamko vd. 2014). Mevcut gelişmiş kredi risk ölçümlerinde kullanılan

² Altman Z-Skoru formülasyonunda finansal raporlardan alınan faktörler kullanılarak firmanın finansal sağlık durumunu gösteren tek bir skor elde edilmektedir. Elde edilen Z skoru belirlenen kesim noktalarına göre modelde yorumlanır.

MKMV (Moody, Kealhofer, McQuown, Vasice), CreditMetrics ve CreditRisk+ gibi modeller Merton modeline ya da risk altındaki değer yaklaşımına dayanır ve piyasa yaklaşımını esas alırlar (Wójcicka-Wójtowicz, 2018). Bu modeller, finansal kurumlar ve yatırımcıların piyasadaki belirsizlik ve değişiklikleri anlamasını sağlayarak portföylerindeki riskleri yönetmelerine yardımcı olur.

1970’li yıllarda yaşanan kriz ve iflaslar sonrası 1988 yılında Basel Bankacılık Gözetim ve Denetim Komitesi tarafından yalnızca kredi riskini odağına alan Basel I kuralları belirlendi (Bulut, 2019). Bu bağlamda, bankacılık sektöründe güvenlik ve sağlam bir yapı sağlamak için önemli bir adım atıldı (Carling vd., 2002). 1980 ve 1990’lı yıllarda yaşanan mali krizler kredi risk değerlendirmelerinin önemini arttırdı (Galindo ve Tamayo, 2000). Merkez bankacıları, bu ekonomik olumsuzluk dönemleri için bankaların kredi riskinin ve batık kredilerinin seviyesinin oldukça etkili olduğunu kabul etmişlerdir (Naili ve Lahrichi, 2020). Kredi riski, bankalar ve finansal kuruluşlar için merkez bankaları ve denetçiler tarafından dış değerlemeye tabi olduğundan hassas bir konu olmuştur (Markov vd., 2022).

20. yüzyılın ortalarında kredi risk analizlerine yönelik yapılan bilimsel çalışmalar, Basel kriterleri ve dünyadaki finansal krizlerin soruna dikkat çekmesiyle 1990 ve 2000’li yıllara kadar belirli bir gelişme gösterdi. Teknolojik ilerleme ile hesaplama kapasitelerinin hızlanması araştırma alanında yapılan çalışmaların sayısının katlanarak artmasını sağladı (Markov vd., 2022). 1977 yılında, lojistik regresyon yöntemi banka krizlerinde erken uyarı sınıflandırılmasında kullanıldı (Martin, 1977). 1980 yılında, James A. Ohlson lojistik regresyon analizini (koşullu logit model) ilk defa tahminleme için kullanarak potansiyel müşteriler için temerrüt olasılığını belirledi (Ohlson, 1980). 1990’lı yılların başına kadar analitik yeteneklerin yargısal sistemlere dahil edilmesi için uzman sistemlere odaklanan girişimler oldu (Doupous vd., 2019). 1980’li yılların son dönemlerinde sinir ağları gibi makine öğrenmesi teknikleri, kural bazlı uzman sistemler ve vaka bazlı tahminleme yöntemleri iflas tahminlerinde uygulanmaya başlandı (Min ve Lee, 2005).

1989 yılında, kredi uzmanlarının yaptığı çalışmalara karşı devam eden önyargıların önüne geçebilmek için FICO tüketici kredibilitesini ölçen derecelendirme skorunu geliştirmiştir (Njuguna ve Sowon, 2021; Sytnychenko, 2023). Geçmiş verilerin istatistiksel analizlerine dayalı bu metod ile kredi riskinin değerlendirilmesi daha ölçülebilir hale gelmiştir (Ptak-Chmielewska, 2016). Zaman içerisinde kredi puanlarının sigorta, istihdam ve mülk kiralama gibi farklı kullanım alanlarının oluşmasıyla daha da yaygınlaşmıştır (Njuguna ve Sowon, 2021).

1990'lı yıllarda kredi riski modelleri risk portföyü üzerine yoğunlaşmıştır ve Merton modeline dayanan MKMV modeli geliştirilmiştir (Kealhofer, 2003). Ayrıca, makine öğrenmesinin borç verme kararlarında ve kredi riski yönetiminin iyileştirilmesinde taşıdığı fırsatları araştıran bir dizi çalışma Bankacılık ve Finans Dergisi'nde yayınlanmıştır (Aziz vd., 2022). 1991 yılında denetimli yapay sinir ağları, belirli bir örneklem kapsamında iflas tahmini için kullanılmıştır (Kim ve Scott, 1991, akt. Saunders ve Allen, 2002). 1994 yılında, İtalyan firmalarının kredi risk analizlerinde sinir ağları kullanılmıştır (Altman vd., 1994). 1997 yılında ise Jarrow, Lando ve Turnbull, yapısal formdaki modellerin bazı sorunlarını ortadan kaldırmak için ilk indirgenmiş kredi modeli çalışmasını yayınlamıştır (Adamko vd. 2014). Aynı yıl JP Morgan tarafından CreditMetrics yaklaşımı yayınlanmıştır (Crouhy vd., 2000)³. 1990'lı yılların sonu ve 2000'li yılların başında geleneksel kredi değerlendirme modellerinin sınırlamalarının fark edilmesiyle makine öğrenmesi teknikleri ön plana çıkmaya başlamıştır. Kredi skorumla tekniklerinin kullanıldığı alanlar artmış ve temerrüt riski ölçümlemesi, müşterilerden elde edilecek kârın maksimize edilmesi yönünde yeni bir rol üstlenmiştir (Abdou ve Pointon, 2011).

21. yüzyılın başlarında, gelişen teknoloji ve ROC eğrisi (Alıcı İşletim Karakteristik Eğrisi) ve gini indeksi gibi değerlendirme kriterlerindeki gelişmiş teknikler çalışmaların ilerlemesine katkı sağlamıştır (Abdou ve Pointon, 2011). 2003 yılında, destek vektör makineleri (DVM) kredi skorumla analizinde ilk kez kullanılmış ve diğer metotlara göre olan performansı da karşılaştırılmıştır (Baesens vd., 2003). Bundan sonrasında destek vektör makineleri kredi skorumla alanındaki araştırmalarda ve modellemelerde kullanılan popüler bir yöntem olmuştur (Goh ve Lee, 2019).

2007 ve 2010 yılları arasında, borç verme sırasında yetersiz kredi risk skorumlasından kaynaklı yüksek riskli konut kredisi krizi yaşanmıştır (Bhatore vd., 2020). 2008 krizinden sonra kredi riski yönetimine artan ilgi kredi riski modellemesinde daha karmaşık model yapılarının gelişmesini sağlarken; Basel çerçevesi ve stres testi⁴ düzenleyiciler de daha ileri modelleme çalışmalarının yapılmasını sağlamıştır (Zamore vd., 2018). 2016 yılında yayımlanan bir araştırma, kredi ve iflas riski üzerine yapılan çalışmaların istatistik ve makine öğrenmesi yöntemlerini birleştiren hibrit modellerin giderek arttığını göstermiştir (Prado vd., 2016). 2018

³ Genellikle bir yıl olarak tercih edilen belirli bir zaman dilimi içerisinde temerrüt dahil kredi kaliteleri arasındaki geçiş olasılığına dayanır. Kredi kaynaklı riske maruz değer ile portföy riskini değerlendirir.

⁴ Stres testleri, herhangi bir portföyün, finansal kuruluşun ya da finansal sistemin şoklar ve olağan dışı piyasa koşulları altında kırılganlığını değerlendiren tekniklerdir (Beşe, 2007).

yılında Uluslararası Finansal Raporlama bağlamında finansal araçların uygulanmasına ilişkin yeni uygulama, kredi puanlama modellerinin muhasebe açısından değerlendirme şeklini etkilemiştir (Bhatore vd., 2020).

Son zamanlarda büyük veri ve veri bilimi yaklaşımları ile makine öğrenmesi algoritmaları kredi riski modellemesinde önemli bir rol oynamaktadır (Addo vd., 2018). Hatta, finansal teknoloji firmaları (fintech), taraflar arasında bir arayüz sağlayarak kredi değerliliğini oldukça kısa sürelerde ölçmektedir (Vives, 2017; Goodell vd., 2021). Bu firmalar ayrıca, teminatsız krediler için borç verme platformları tasarlamaktadır (Vives, 2017; Goodell vd., 2021). Günümüzde artan veri hacmi ve COVID-19 pandemi döneminin etkisiyle kredi risk modelleri karmaşılaşmaya ve gelişmeye devam etmektedir.

Tarihin derinliklerinden günümüze kadar farklı yöntem ve uygulamalara konu olan kredi riskinin etkin yönetimi finansal sistemlerin sağlıklı işlemesi ve ekonomik istikrarın sürdürülmesi için önemlidir. Nitekim, ölçülemeyen riskler yönetilmesi zor belirsizliklere yol açabilir ve bu durumdan kredinin tarafı olan tüm paydaşlar olumsuz etkilenebilir.

2.3. Kredi Riskinin Önemi


Dijitalleşmeyle hayatımıza hızla giren teknolojik gelişmeler, belirsizlik ortamı ve küresel rekabet ile şekillenen yeni dünya düzeni kurumların maruz kaldığı riskleri daha öngörülemez hale getirmiştir. Finansal piyasalardaki dalgalanmalar ve şoklar belirli bir bölge ile sınırlı kalmamakta (Choi, 2022) dünyanın ücra bir noktasında gerçekleşen risk dahi çok hızlı bir şekilde küresel piyasaları etkilemektedir. 2007 – 2008 küresel mali krizi ile bu etki görülmüş; kredi riski, banka ve finansal piyasaların odağı haline gelmiştir (Bhatore vd., 2020). Yaşanan likidite sorunları tüm dünyayı etkisi altına almış ve büyük buhrandan sonra yaşanan en büyük finansal ve ekonomik çöküş yaşanmıştır. Bu bağlamda, kredi riski finansal istikrarsızlığa yol açma potansiyeli ile giderek daha önemli hale gelmiştir.

Kredi riski, sermaye erişim maliyetlerini etkilemesi bakımından da önemlidir. Faiz oranlarının artması kredi maliyetlerini arttırmakta ve borç alanların borçlarını geri ödememe riskini arttırmaktadır. Bu durum ekonomik faaliyetleri olumsuz etkileyebilir ve sermayeye erişim kısıtlanabilir. Tarihsel olarak yüksek borç yükleri de göz önüne alındığında hükümetler açısından piyasadaki kredi riski önemini korumaya devam edecektir. Zira, artan faiz oranları ya da borçlanmalar temerrüt ve iflas risklerini beraberinde getirecektir. Sorunlu krediler ve kredi

temerrütlerinin finansal kurumların kârlılığını ve istikrarını etkilemesinden dolayı ülke ekonomileri de olumsuz etkilenecektir (Shoumo vd., 2019).

Dünya Ekonomik Forumu (WEF, 2024) tarafından, küresel ölçekteki riskler hakkında yapılan çalışmaya göre önümüzdeki 10 yıl içerisinde borçluluğun risk algısı devam edecektir ve risk yönetiminde ilk sırada yer alacaktır (bkz. Şekil 2.2.). Çalışmada, yavaşlayan büyüme ortamının kamu ve özel sektörün borç yükünü artıracak ve birçok ekonominin belkemiği olan küçük ve orta ölçekli şirketlerin yüksek faiz oranlarına karşı daha hassas hale geleceği belirtilmiştir. Bu durumun daha derin bir olumsuz ekonomik döngüye yol açmasının kaçınılmaz olacağı aşikardır.

Şekil 2.2. Finansal Araçların Ele Aldığı Başlıca Küresel Riskler




Kaynak: WEF (2024)

Özellikle, yeni ekonomik şokların ve kırılganlığın arttığı bu ortamlarda, borcun sürdürülebilirliği sorun teşkil etmektedir (WEF, 2024). COVID-19 pandemi sürecinden etkilenen ticari ilişkiler ve tedarik zincirleri, zincirleme iflasların olma korkusunu arttırmış ve kredi veren tarafları daha temkinli olmaya itmiştir. Firmaların ödeme gücünü ve likidite durumlarını etkileyen ticari alacak kredisi daha önemli hale gelmiş; yaşanan olumsuzluklardan etkilenen üretim ve satış hacimleri nedeniyle tahsilatlarda gecikmeler ve vade uzatım talepleri baş göstermiştir (Eke ve Toprak, 2020). Yaşanan likidite sorunu, kredinin küresel ve yerel ekonomilerdeki önemini bir kez daha vurgulamış ve hükümetler krediye erişimi destekleyici politikalar hayata geçirmeye başlamışlardır. Tarihsel perspektiften bakıldığında, kredinin borç

veren ve borç alanlar taraflarca makul ve uygun bir şekilde kullanılmadığı takdirde küresel ekonominin zarar gördüğü çok sayıda örnek karşımıza çıkar. Kredi risk analizinin yeterli olmaması ya da kredi riskinin iyi yönetilmemesi halinde tüm paydaşların bu durumdan olumsuz etkilendiği söylenebilir (Joseph, 2013). Bu bağlamda, işletme sermayesinin etkin kullanılmaması, alacak politikası ve stok yönetiminde verimsizliğe sebep olacağı gibi yeterli olmayan işletme sermayesi özellikle kısa vadeli borçların ödenmesinde sorun teşkil edecektir. Bu nedenle, işletmeler belirleyecekleri risk tutumuna göre kredi risk yönetim stratejileri geliştirmeli ve varlıklarını etkin kullanmalıdırlar (Karaca, 2020).


Allianz Trade (2023), tarafından yapılan şirketlerin ödeme yapamama risk haritasına göre Türkiye en yüksek riskli sınıfta yer almaktadır (bkz. Şekil 2.3.). Ayrıca, Türkiye’de 2024 yılı ocak ayı itibarıyla değerlendirildiğinde, geçmiş son 5 yılda yıllık ortalama karşılıksız işlemi yapılan çek tutarının yaklaşık on katına çıktığını ve çek adetinde artış olduğu görülmektedir (bkz. Şekil 2.4.). Protestolu senet tutarında da artış mevcuttur. Bu durum, işletme sermayesi ihtiyacının arttığı bu dönemde borçların geri ödenmesinde sorunlar olduğunu gösteren bir işaret niteliğindedir. Bu nedenle, firmaların etkili bir nakit akış yönetim süreci yürütmeleri için kredi risk iştahlarını iyi belirlemeleri gerekmektedir. Çünkü, kredi sağlayan taraflar, verdikleri borç miktarını işletme sermayesinde kullanamazlar ve beraberinde gelecek ek maliyetlere katlanmak durumunda kalabilirler.

Şekil 2.3. Ülke Bazlı Şirket Ödeme Yapamama Risk Haritası



Kaynak: Allianz Trade (2023)

Şekil 2.4. Karşılıksız İşlemi Yapılan Çek ve Protestolu Senetler



Kaynak: Türkiye Bankalar Birliği Risk Merkezi (2024a), Türkiye Bankalar Birliği Risk Merkezi (2024b) verileri esas alınarak Yazar tarafından oluşturulmuştur.

Bu nedenlerle, etkin bir kredi riski yönetiminin olması; kaynakların verimli kullanılması, finansal istikrarın korunması, ekonomik büyümenin desteklenmesi ve finansal kurumların ve ekonomilerin olası krizlere karşı dayanıklılığının sağlanması açısından oldukça önemlidir.

2.4. Literatür Taraması

Birbirleriyle ilişkisi artan riskler nedeniyle artık tek başına olan bir risk düşünmek de oldukça zordur. Kredi riski de ekonomik çevre ve faktörler (döviz kuru, faiz, makro ekonomik göstergeler, döviz kuru, enflasyon, büyüme vs.) (Ball ve Mankiw, 1995; Kamin ve Rogers, 2000; Yurdakul, 2014; Kırkıl, 2021), arz ve talep değişiklikleri (Koulouridi vd., 2020; Ağca vd., 2023; Lo Duca vd., 2024), belirsizlik (Manzo, 2013; Chi ve Li, 2017), teknoloji (Lei, 2014; Bahillo vd., 2016; Yang vd., 2016; Sun vd., 2024), yolsuzluk (Hasan ve Ashfaq, 2021; Jenkins vd., 2023) ve çevre (iklim değişikliği, karbon ayak izi, doğal afetler vb.) (Kabir vd., 2021; Lai vd., 2022; Di Tommaso vd., 2023) gibi tüm dünyayı etkisi altına alabilen birçok farklı risk ile yoğun etkileşim içerisinde. Bu çalışmalara göre kredi ve kredi riskinin hem bir etki unsuru olduğu hem de çeşitli faktörlerden etkilendiği görülmektedir. Bu nedenle, kredi riskinin yönetimi kompleks ve çok boyutludur (Wójcicka-Wójtowicz, 2018). Literatürde yer alan çalışmaların bazılarını aşağıda değinilmiştir.

Yang vd. (2016), çalışmasında kredi riskinin ölçülmesinde sosyal medyanın etkili olabileceğinin ilk kanıtını göstermiştir. Çin’de yer alan yatırım firmaları arasında en popüler

olan iki uygulamadan aldıkları gönderi ve yorumlardan metin analizi yapmışlardır. Probit, logit ve sosyal medya modeli ile 2009 ila 2014 yılları arasında Çinli firmaların mali verilerini incelemişlerdir. Bulgu sonuçlarında, sosyal medya üzerinden gelen kitlesel bilgilerin alanındaki uzmanlara göre daha doğru sonuçlar verdiği tespit edilmiştir. Ayrıca, menkul kıymet firmalarında çalışan analistlerin kamuoyunu yanıltma olasılıklarının yüksek olduğu belirtilmiştir.

Bahillo vd. (2016), çalışmalarında banka müşterilerinin taleplerinin değiştiğini, çevrimiçi ve mobil uygulamalara yönelik işlem hacimlerinde artış olduğunu belirtmişlerdir. Müşteri beklentileri doğrultusunda kredi onaylarında hız ve basitlik açısından ihtiyacın karşılanmakta zorlanıldığına değinilmiştir. Aynı zamanda, risk yöneticileri gibi kurumsal çalışanların, raporlama süreçlerindeki kalite ve hız konusundaki beklentileri daha belirgin hale gelmiştir. Kredilendirme süreçlerinin otomasyonu ve dijitalleştirilmesi ile beklentilerin karşılanabileceği ve maliyetlerde %50'ye kadar tasarruf sağlanabileceği belirtilmiştir.

Koulouridi vd. (2020), çalışmada COVID-19 döneminde mevcut kredi risk modellerinin yetersiz kaldığını ve kredi riski bağlamında değişen ana beş bileşen olduğunu açıklamıştır. Bunlardan ilki, krizden farklı şekillerde etkilenen sektör ve alt sektörlerin kredibilite seviyelerindeki değişimdir. Bu nedenle, talep şoklarının ve toparlanma seviyelerinin temerrüt olasılığında kullanılabileceğine yer verilmiştir. Borçlunun iş modeli ve finansalların daha derin incelenmesi, nakit akışı ve likidite işlem verileri için yüksek frekanslı veriler ile sistemin otomatik beslenmesi ve sektörler özelinde çözüm yöntemleri geliştirilmesi bu bileşenler için olası yeni yaklaşımlar olarak belirtilmiştir. Kredi riskinin yönetiminde veri analizi ve yeteneklerinin önemi vurgulanmıştır.

Kırkıl (2021), çalışmada ülkelerin temerrüt olasılığının ekonomik veriler ile ilişkisini araştırmıştır. 2008 ila 2017 yılları arasındaki G20 kapsamında yer alan ülkelerin verilerinden yararlandığı bu çalışmada lojistik regresyon yöntemini kullanmıştır. Bu ülkeler içerisinde yer alan Türkiye'nin temerrüde düşmeme olasılığı 2014 yılından sonra 0,15 puan düşüş ile %70 seviyesine gelmiştir. Bu duruma 2013 yılı itibarıyla dolar kurundaki artış ve dolar kuru üzerinden incelenen GSYİH'de azalma olması etken sebep olarak gösterilmiştir. Çalışmanın genelinde, dış faktörlerin etkisiyle döviz kuru olumsuz etkilenen ve rezerv paraları düşük ülkelerde temerrüt olasılığının arttığı görülmüştür.

Kabir vd. (2021), 2004-2018 dönemini kapsayan ve farklı ülkelerde olan 2785 firmada karbon emisyonlarının temerrüt riski arasında pozitif ilişki olduğunu bulmuştur. Firmaların

çevresel çalışmalarının bunun etkisini azalttığı ve politik kararlarda dikkate alınabileceği belirtilmiştir.

Lo Duca vd., (2024), makroekonomik ve para politikası şoklarının firmaların kredi riskine etkisi incelenmiş ve arzın daralmasının da etkisiyle ülke seviyesinde temerrüt olasılık seviyelerinin kayda değer bir biçimde etkilediğini ileri sürmüştür. Firma düzeyinde mali açıdan sıkıntılı olup banka kredilerine bağımlı olan görece daha küçük firmaların bu şoklardan daha fazla etkilendiği tespit edilmiştir. Para politikası değişimleri daha çok finansal sektöre etki ederken; inşaat, emlak, ulaştırma ve ticaret gibi sektörler arz ve talep şoklarından etkilenmiştir.

Sun vd. (2024), çalışmada dijital ekonominin gelişimi ile ticari bankaların kredi risklerinin azalabileceğini ve batık kredi oranlarındaki artışın engellenebileceği sonucuna ulaşmışlardır. Çin bankalarından alınan verilerden yararlanılarak yapılan çalışmada 2013 ve 2021 dönemi kapsayan veriler kullanılmıştır. Ayrıca, mali denetim harcamaları ve yasal kurumsal endeks değişkenlerinin kredi riskini azaltabileceği sonucuna varmışlardır. Dijital ekonominin gelişmesinin finansal denetim yeteneklerini güçlendireceği ve böylelikle kredi riski denetiminin karmaşıklığı ve değişkenliğinin daha iyi yönetileceği bulgusuna ulaşılmıştır.

20. yüzyılda küreselleşme ve artan teknoloji ile kredi dünyasında yeni gelişmeler yaşanmış; kredi kartları ve elektronik bankacılık işlemleri ile kredi riskinin önemi artmaya devam etmiştir. Artan borçlanmalar ve küresel iflaslar kredi riskinin analiz ve değerlendirmesinin kritik bir unsur haline gelmesini sağlamıştır (Gavrilaková vd., 2014). COVID-19 pandemi dönemi kredi riski yönetiminde karar mekanizmalarını destekleyici geri bildirimleri ve bunları sağlayacak gerçek zamanlı veri analizlerini ön plana çıkarmıştır (Koulouridi, vd., 2020).

Kredi piyasalarının son yıllarda yaşadığı olağanüstü bir büyüme, bu eğilimin önümüzdeki yıllarda devam etme beklentisi göz önüne alındığında, firmaların kredi riski değerlendirme yeteneklerini geliştirmeleri gerekmektedir (Bruni vd., 2014).

BÖLÜM 3: KREDİ RİSKİ DEĞERLENDİRME

Modern finansal sistemler krediye dayalı olarak ilerlemektedir (Widagdo vd., 2023) ve kredi borcunu ödeme aczine düşen ve zarar yazılanların oranı tüm zamanların en yüksek seviyelerinde seyretmektedir (Shoumo vd., 2019). Bu nedenle, kredi riskinin değerlendirilmesi her zamankinden daha önemli hale gelmiştir (Shoumo vd., 2019). Kredi riskinin günümüzde artan önemi ve beraberinde getirebileceği negatif etkiler, kredi risklerinin tüm dünyada ön plana çıkmasını sağlamış; makine öğrenmesi alanındaki gelişim dalgasıyla birlikte sektör ve akademik dünyada kendine geniş bir araştırma alanı bulmuştur (Shi vd., 2022).

3.1. Çalışmanın Amacı ve Kapsamı

Özellikle, Türkiye gibi dışa bağımlı ve kırılganlıkların fazla olduğu ekonomilerde kredi riskinin etkin yönetimi, firmaların sürdürülebilirliği ve kârlılıkları açısından diğer ekonomilere kıyasla daha fazla önem arz etmektedir. Sermaye erişim maliyetinin yüksek olduğu durumlarda borçlu taraflar ödeme aczine düşebilir, vade öteleme talepleri oluşabilir ve hatta iflaslar artabilir. Diğer yandan, yüksek faiz ya da alternatif yatırım araçlarından elde edilecek finansal kârın, operasyonel kârdan daha fazla bir kazanç sağlaması tarafları cezbedebilir ve sahip olunan sermayenin farklı alanlarda kullanımı için yönlendirebilir. Bu durum, kredi veren taraflar için kredi riskini arttırabilir ve nakit akış yönetiminde sıkıntılara sebep olabilir. Üretim ve satışların etkilenmesinin ülke ekonomisine olumsuz yansımaları olur: borçlanmalar artar, kredi daralması yaşanır, ekonomik büyüme yavaşlar ve istihdam olumsuz yönde etkilenir. Dolayısıyla, firmaların alacak tahsilindeki risklerini iyi yönetebilmeleri hem rekabet güçlerinin artmasını sağlar hem de ülke ekonomisinin istikrarına destek olur.

Kredi riski değerlendirmesinin temel amacı, borçlunun temerrüt olasılığını ölçmek ve kredi riskine neden olacak olası faktörlere ilişkin analiz ve hesaplamalar ile kredi verenin karar vermesine destek olunmasıdır (Yang, 2014). Bu bağlamda, çalışmanın amacı özel sektörde faaliyet gösteren bir firmanın ticari ilişki içerisinde olduğu müşteri verilerinden faydalanılarak vade aşım olasılığı ile kredi riskini tahmin eden bir model geliştirilmiştir. Uygulama ile müşterilerin ödeme performansındaki olası zararın önceden görünür hale gelmesi ve işletme sermayesinin etkin kullanımının sağlanması hedeflenmektedir. Ayrıca, borçlunun geç ödemesine etki edecek içsel ve ekonomik faktörleri ile bu faktörlerin önem seviyelerini tespit

edebilmektedir. Çalışmanın bir diğer amacı, yaygın makine öğrenmesi tekniklerine göre modeli karşılaştırılarak en iyi performansı gösteren yöntemin bulunmasıdır.

Çalışma kapsamında, analizi yapılan firmanın 2022 yılında çalışmış olduğu 565 adet müşterinin ticari bilgilerinden oluşan 12 adet kurum içi değişken ve dışsal kaynaklı 7 adet ekonomik değişken olmak üzere toplam 19 adet bağımsız değişken kullanılarak, yeni bir sipariş alındığında borcun zamanında ödenip ödenmeyeceği sorusuna cevap aranmıştır. Bu kapsamda, literatürde ve uygulamalarda geniş yer alan geleneksel istatistiksel yöntemlerden doğrusal ayırma analizi, lojistik regresyon ve probit yöntemleri incelenirken; makine öğrenmesi algoritmalarından destek vektör makineleri, k-en yakın komşu, rastgele orman, gradyan artırma ve aşırı gradyan artırma yöntemleri kullanılmıştır. Bu yöntemlerden makine öğrenmesine ait olanlar ile uygulamanın modeli geliştirilmiştir.

3.2. Çalışmanın Kısıtları

Çalışma kapsamında firma verileri ticari gizlilik ve mahremiyet kapsamında korunacaktır. Ayrıca, etik değerler kapsamında müşteri unvan veya kimliğini ortaya çıkarıcı herhangi bir veri paylaşılmamış ve bu yönde bir veri talep edilmemiştir.

3.3. Kredi Riski Değerlendirmesinde Kullanılan Yöntemler

Kredi riski modelleme yaklaşımlarında kullanılan temel iki parametre, temerrüt olasılığı (PD, probability of default) ve temerrüt halinde kayıp (LGD, The loss given default) olarak belirtilebilir (Hao ve vd., 2010). Kredi riskinde beklenen kaybın hesaplanmasında bu iki değer kullanılmaktadır. Temerrüt olasılığı riske esas tutar ve geri dönüş oranı ile hesaplanmaktadır (Brown ve Moles, 2011). Beklenen kayıp, karşı tarafın temerrüde düşmesi halinde uğranan zararın, temerrüt anında ödenmemiş tutara oranıdır (Spuchl'akova ve Cug, 2015). Beklenen kayıp hesabına ilişkin formül ve değişken tanımları aşağıdaki gibidir (bkz. Tablo 3.1):

$$\text{Beklenen Kayıp} = \text{Riske Esas Tutar} * \text{Temerrüt Olasılığı} * (1 - \text{Geri Dönüş Oranı})$$

Tablo 3.1. Beklenen Kayıp Değişkenleri

DEĞİŞKENLER	TANIMLAR
Temerrüt Olasılığı	Borçlunun belirlenen zaman dilimi içerisindeki yükümlülüğünü yerine getirememesi olasılığını temsil eder.
Riske Esas Tutar	Borçlunun temerrüde düşmesi durumunda yükümlülüğünün teminat değeri hariç tutarını gösterir.
Geri Dönüş Oranı	Temerrüt halinin gerçekleşmesi sonrasında oluşan zarar miktarının hangi oranda borçludan tahsil edilebileceğini ifade etmektedir.
Temerrüt Halinde Kayıp Oranı	Temerrüt durumunda tahsili mümkün olmayan zararın oransal ifadesidir. Geri dönüş oranının 1 değerinden çıkarılması ile hesaplanır. Zararın ölçüsü kullanılan teminat araçlarına bağlı olarak değişkenlik gösterebilir.

Kaynak: BCBS-Basel II (2004), Sá ve Pereira (2015) ve Javier (2017) kaynaklarından yararlanarak Yazar tarafından oluşturulmuştur.

Günümüzde kayıplar risk unsurlarının korelasyonlarının yüksek olması ve risk faktörlerinin birbirlerinden bağımsız olmamaları nedeniyle beklenenin ötesinde gerçekleşmektedir (İltaş, 2021). Beklenmeyen kayıp belirsizlik ve gerçekleşecek kaybın standart sapmasından dolayı oluşabilecek kaybı tanımlarken, beklenen kaybın volalitesi olarak açıklanmaktadır (Saunders ve Allen, 2002). Etkin bir risk yönetimi için ekonomik gelişmeler, sektör ya da diğer etkenler ile gelişebilecek belirsizlik durumları için beklenmeyen kaybın dikkate alınması gerekmektedir (Brown ve Moles, 2011).

Kredi riskinin değerlendirilmesi karmaşık ve farklı boyutlara sahip olduğu için niceliksel ve niteliksel değerlendirmeler içeren farklı yaklaşımlar bulunmaktadır (Brown ve Moles, 2011). Bazı yöntemler öznel yargı metotları ile değerlendirme yaparken bazıları objektif değerlendirmeler için daha sistematik bir yaklaşım sergilemektedirler. Uygulamada bu yöntemlerin kombinasyonu kullanılabilir. İlk uygulamalar olan subjektif değerlendirmelerden sonra kredi risk değerlendirmesinin 1930'lu yıllar itibarıyla oransal, istatistiksel ve yapay zekâ olmak üzere üç temel farklı analiz aşamasından (Tablo 3.2) geçtiği söylenebilir (Ma ve Guo, 2010).

Tablo 3.2. Kredi Riskinin Gelişiminde Değerlendirme Yaklaşım ve Yöntemleri

YAKLAŞIM	ÖRNEK METOTLAR	METODOLOJİ
Uzman Yargısal Değerlendirme Yöntemleri	5C, 5W ve 5P Analiz Modeli	Borçlandırma sistemi ve prosedürleri aracılığıyla değerlendirilebilir. Geçmiş bilgi ve veriler ile nispeten daha istikrarlı yapılan çalışmalar olsa da yargılar öznelidir.
İstatiksel Yöntemler	Ayrırma Analizleri, Z-Skoru Modeli, Probit Model, Logit Model, Doğrusal Olasılık Modeli (Lineer Olasılık Modeli), Temel Bileşen Analizi, Kredi Skorlama	Karar verme sürecinde uygun ilişki çıkarımlarını sağlamak için istatistiksel modeller kullanılır.
Piyasa Yaklaşım Metotları / Matematiksel Temelli Yöntemler	MKMV, Credit Metric, Credit Risk + ve VAR modeli	Finansal ödeme gücünde, finansal piyasadaki fiyatların bilgi içeriklerini değişken olarak baz alır. Dış faktörler de değerlendirilir.
Yapay Zekâ / Makine Öğrenmesi Yöntemleri	Rasgele Orman, Karar Ağaçları, Destek Vektör Makineleri, Yapay Sinir Ağları, Gradyan Artırma, Aşırı Gradyan Artırma (XGBoost), Derin Sinir Ağları, Bayes Ağı	Örüntüleri belirlemek ve anlamlı öneriler oluşturmak için büyük veri kümelerinden yararlanır. Yüksek boyutlu verilerde işlem yapmayı kolaylaştırmıştır.

Kaynak: Song vd. (2023) ve Brown ve Moles (2011)’den yararlanılarak Yazar tarafından oluşturulmuştur.

Uzmanlar tarafından yapılan değerlendirmelerde yargıya dayalı alınan kararlar, çeşitli form ve süreçler kullanılarak daha sistematik hale getirilmektedir. Bu süreçte genellikle, kredi değerliliğini ölçerken ‘5C’ ve kredi başvuru değerlendirmelerinde ‘5P’ analizi kullanılarak beş faktörlü inceleme yapılmaktadır (Abbadi ve Karsh, 2013). Faktörlerin ağırlıkları subjektif olarak verildiği için değerlendirme yapan uzmanın yetkinliği, tecrübesi, risk algı ve iştahı verilen karar sonucunu etkilemektedir. Ancak, karar verirken her bir firma için kredi riskini etkileyen faktörlerin incelenmesi ve önceki aşamada seçilen faktörlerin bir araya getirilerek belirlenen tercih sistemine göre değerlendirmesi gerekmektedir. Kredi değerlendirme sürecinin bu karmaşıklığı finansman arayışında olan yeni firmalar ve mevcut firmaların incelemesi için derecelendirme yaklaşımına dayalı modellerin oluşturulmasını gerekli kılmıştır (Doumplos vd., 2002).

5C analizi; “(1) Karakter (Ödemeyi geri yapma konusunda isteklilik), (2) Kapasite (borcu geri ödeyebilecek finansal yeterlilik), (3 -4) Sermaye ve Teminat (ödeme yapılabilecek

öz kaynaklar veya teminat) ve (5) Koşullar (Genel ekonomik durumu, borçluya uygulanan özel koşulları ya da kredi tipini) unsurlarını yansıtır” (Rosenberg ve Gleit, 1994).

5P Analizi; “(1) İnsan (Borçlunun mali yükümlülüklerini yerine getirebilmesi için geçmiş bilgileri), (2) Amaç (Kredinin ne amaçla kullanılacağına dair açıklama), (3) Ödeme (Amaç doğrultusunda belirlenen nakit akışa dayalı geri ödeme planı), (4) Koruma (Geri ödeme için teminat ve ikincil kaynaklar), (5) Plan (Kredinin denetleme ve izleme faaliyetleri ile temerrüt halinde alınacak aksiyon planı)” unsurlarından oluşur (Abbadi ve Karsh, 2013).

Kredi puanlama modelleri bir uzmanın hatırlayabileceğinden daha fazla müşteri ve bunların verileri üzerine çalışır. Böylelikle, yalnızca kabul edilen ve daha sonra temerrüde düşenler yerine (Crook, 1996, akt. Abdou ve Pointon, 2011) iyi ve kötü ödeme yapan tüm başvuruları dikkate aldığı için önyargıların önüne geçer (Abdou ve Pointon, 2011). Ancak, bu yöntemin, olası tüm değişkenleri içermediği sürece yanlış sonuçlar verebileceğini belirtmek gerekir (Heffernan, 2005).

İstatistiksel yaklaşımlardan tek değişkenli analiz yöntemleri genellikle mali tablo verilerini esas alır ve temerrüt riskine odaklanır. Ancak, bu yöntemin rasyo değerleri ile olası başarısızlığın tahmini arasında anlamlı bir ilişki kurulamaması (Narzhanov, 2011) nedeniyle iki veya daha fazla değişkenin kombinasyonu ile başa çıkabilen yeni metotlar gelişmiştir (Prado vd., 2016). Böylelikle, doğrusal olasılık modeli, logit model, probit model ve doğrusal ayırma analizi gibi istatistikî yöntemler yaygın olarak kullanılmaya başlanmıştır (Hamerle vd., 2003).

Kredi riskini ölçmek için piyasa yaklaşımını esas alan portföy kredi riski ölçüm modelleri arasında KMV, Credit Metric, Credit Risk + ve VAR modelleri yer alır. Merton tabanlı modeller, tarihsel temerrüt oranı yaklaşımı ve sermayenin risk ayarlı getirisi yaklaşımı kredi riskinin ölçülmesinde kullanılan yeni yöntemler olup piyasa yaklaşımını esas alırlar (İltaş, 2021).

Makine öğrenmesi yöntemlerinde, arttırma (boosting) ve torbalama (bagging) teknikleri ile farklı model kombinasyonları kullanılabilir. Karar ağaçları, AdaBoost, gradyan artırma ve aşırı gradyan artırma bu yöntemlere örnek olarak gösterilebilir.

Gerçek dünyada veriler karmaşık, doğrusal olmayan ve kendilerine özgü özelliklere sahip olmaları nedeniyle istatistik ve makine öğrenimi ile verileri birleştiren disiplinler arası bir yaklaşım benimsemek iyi bir strateji oluşturur (Galindo ve Tamayo, 2000).

Kredi riskinin değerlendirme yöntemlerinde geleneksel ve makine öğrenmesi olmak üzere iki başlık altında incelenmiştir. Çalışma kapsamında incelenecek olan yöntemler sonraki başlıklarda detaylı olarak incelenmiştir.

3.3.1. Geleneksel Yöntemler

Lojistik regresyon (Ohlson, 1980), doğrusal ayırma analizi (Durand, 1941; Smith, 1964; Beaver, 1966), çoklu ayırma analizi (Altman, 1968; Deakin, 1972; Altman, 2005) ve probit model (Grabrowsky ve Talley, 1981; Zmijewski, 1984; Boyes vd., 1989) gibi parametrik istatistiksel modeller, kredi riski değerlendirmesinde yaygın olarak uygulanmaktadır (Douplos vd., 2002).

i. Doğrusal Ayırma Analizi

Ayırma analizi, benzer özelliklere sahip yeni bir ögenin dahil olabileceği kategorileri tahmin edebilen bir sınıflandırma algoritmasıdır (Sueyoshi, 2006). 1936 yılında R.A. Fisher tarafından biyolojide taksonomik sınıflandırma için önerilmiştir ve bu alanda kullanılan en yaygın istatistiksel teknik olarak bilinmektedir (Lee vd., 2006). İki veya daha fazla nesne veya olayın sınıflarını karakterize eden veya bunları ayıran özelliklerin doğrusal kombinasyonunu bulan (Stella, 2019) çok değişkenli istatistiksel bir teknik olarak da tanımlanabilir (Göktaş vd., 2012). Ayırıcı özelliğin ya da bağımlı değişkenin kategorik olduğu ve tahmin değişkeni ya da bağımsız değişkenin doğası gereği aralıklı (interval) olduğu durumlarda verilerin analizinde kullanılmaktadır (Stella, 2019).

İstatistiksel ölçümlerde ayrılabilirlik ortalama değer ve varyans olarak tanımlanır. Doğrusal ayırma analizi, sınıflar arası varyansı başka bir ifadeyle farklılıkları en üst seviyeye çıkararak sınıflar arasındaki doğrusal ayrımı en iyi belirten bir alt uzayı bulmayı amaçlar (Fisher, 1936). Burada fonksiyonun katsayıları büyüklük derecesine göre bağımsız değişkenin gruplandırılmasına etki eden katkı seviyelerini gösterir (Yazıcı, 2018). Böylelikle, tahmin değişkeni açısından gruplar arasında anlamlı bir fark olup olmadığının incelenmesine yardımcı olmaktadır. Örneğin, banka kredi müşterilerinin özelliklerine göre düşük ve yüksek risk sınıflarına ayrılabilir (Altman ve Saunders, 1997).

Ayırma analizi ilişkisel birkaç istatistiksel yaklaşımı kapsadığından dolayı geniş bir kavramdır (Klecka, 1980). Kategorilerin, başka bir ifadeyle bağımlı değişkenin sayısı ikiden fazla olduğunda çoklu ayırma analizi (MDA) kullanılmaktadır (Sundaram, 2001). Bu yöntem, gruplar arasında en iyi ayrımı yapan özelliklerin doğrusal bir kombinasyonunu oluşturmaya çalışan istatistiksel bir tekniktir (Altman, 1968; Altman and Hotchkiss, 2006). İki gruplu ayırma analizinden farklı olarak grupları ayırmak için tek bir ayırma fonksiyonu yeterli olmadığından gruplar arasında en iyi düzeyde ayrımın yapılmasını sağlayacak en az sayıda ayırma

fonksiyonunun oluşturulması amaçlanmaktadır (Öztaş, 2022). Bağımsız değişkenlerin çok değişkenli normal dağılımda olması ve grup dağılım ya da varyans-kovaryans matrislerinde başarılı ve başarısız grupların denk olması (Bunyaminu ve Issah, 2012), önceki başarısızlık olasılığı ve sınıflandırma maliyetlerinin belirlenmesi ve çoklu bağlantının olmaması varsayımına dayanır (Balcaen ve Ooghe, 2006). Doğrusal ayırma analizinden farklı olarak sınıf içi varyansın en aza indirilmesine odaklanır (Xanthopoulos vd., 2013).

Ayırma analizi, kredi risk analizinin ilk araçlarından biri olarak kabul edilmektedir (Markov vd., 2022). Analizin temerrüt modellemesindeki temel varsayımı, farklı ortalamalarla normal olarak dağılmış iki popülasyonu temerrüde düşme haline göre ayrılmasıdır (Lando, 2009). Mali başarısızlığı tahmin etmede finansal oranları ayrı ayrı ele alan tek değişkenli modellerin çelişkili sonuçlar üretmesi sebebiyle, olayları farklı boyutları ile ele alabilen çoklu ayırma analizi kullanılmaya başlanmıştır (Cangül, 2006).

ii. Lojistik Regresyon

Lojistik regresyon, çoklu sınıflandırmaya da genelleştirilebilen esasen ikili sınıflandırmaya yönelik (Subasi, 2020) olarak geliştirilen tipik bir istatistiksel algoritmadır (Yu vd., 2015). Hem sınıflandırma hem de sınıf olasılık tahmini için kullanılabilir (Bartosik ve Whittingham, 2021). Bağımlı ve bağımsız değişkenler arasında logit bir ilişki olduğunu varsaymaktadır (Bozkurt, 2011).

Adındaki regresyon kelimesini doğrusal regresyondan alıyor olsa da (Gudivada vd., 2016) regresyon modelinden ziyade bir sınıflandırma modeli olarak (Subasi, 2020) doğrusal regresyonun bir dönüşümüdür. Doğrusal regresyondan farklı olarak değişkenlerin sürekli olması ya da normal dağılım göstermesi gerekmemektedir (Lee vd., 2007).

Lojistik regresyon, kredi skortlama modellerinde sıklıkla kullanılan bir yöntemdir (Lee ve Chen, 2005; Lin ve Chen, 2023). Modeldeki ortak değişkenlere bağlı olarak temerrüt olasılığını verebilir (Altman ve Saunders, 1997) veya kredi başvurusunda bulunan borçlunun puanına göre sınıflandırabilir (Guo vd., 2019).

iii. Probit Model

Olasılık birimini temsil eden ‘probit’ terimi 1930’lu yıllarının başında ortaya çıkmıştır. Probit analizi, çok değişkenli ve koşullu olasılık modeli olup katsayı değerlerini hesaplar. Bağımsız değişkenleri işleme tabi tutarken kümülatif standart normal dağılım fonksiyonunu

kullanır ve fonksiyonun çıktısı olan bağımsız değişkeni olasılık değerine dönüştürür (Amat vd., 2017). Çıkan sonuç ikili bir değişken olmayıp; kredi riskinde farklı risk gruplarındaki borçluların taşıdıkları risk oranlarını verir. Kümülatif olasılık dağılımının standartlaştırılmış bir normal dağılım olduğu varsayımı altında önemli bir sınıflandırma tekniğidir (Yu vd., 2015).

Finansal kurumlarda kullanımı en yaygın olan modeldir (Taş, 2023). Kredi müşterilerinin riski, firma iflasları ile kredi temerrüt risklerini tahmin etmekte kullanılmaktadır.

Sonraki bölümde, bu yöntemlerin kredi risk alanındaki kullanımlarının avantaj sağladığı noktalar ve eksik yönlerine değinilecektir.

3.3.1.1. Geleneksel Yöntemlerin Değerlendirilmesi

Kredi risk değerlendirilmesinde kullanılan istatistiki yöntemler, faktörlerin öneminin araştırılmasına ve modelin kalitesinin değerlendirilmesine olanak sağlarlar (Saputri ve Ermatita, 2019).

Bu yöntemlerden doğrusal ayırma analizi, 1990 yılına kadar popülerliğini korumuştur (Karminsky vd., 2020). Anlaşılmasının kolay olması ve çeşitli bilgi teknolojileri sistem ve uygulamalarında kolaylıkla uygulanması büyük avantaj sağlamıştır (Ptak-Chmielewska, 2016). Ancak, bu teknikte bağımsız değişkenlerin normal dağılımı, başarılı ve başarısız sınıflarda eşit varyans kovaryans matrisleri, yanlış sınıflandırma maliyeti ve çoklu bağlantının olmaması varsayımları nedeniyle, gerçek dünyadaki uygulamalardaki ihtiyacı karşılamamaktadır (Balcaen ve Ooghe, 2006). Ancak, başvuru koşuluna ve davranışlardaki rastgele unsurlara bağlı olarak herhangi bir zamanda başvuran temerrüde düşme veya düşmemiş olma sınıflarından her ikisinde de olabilir (Greene, 1992). Bu durum, yöntemin sonuçlarında sapmaya sebep olabilir. Kredi verirken doğru karar verebilmek için popülasyonun ve Tip I ile Tip II hatalarının maliyetinin bilinmesi gerekmektedir (Greene, 1992). Dolayısıyla, verilerin kategorik doğası hakkındaki varsayımı ve farklı sınıfların kovaryans matrislerinin eşit olma ihtimalinin düşük olduğu gerçeği nedeniyle sıklıkla eleştirilmiştir (Reichert vd., 1983). Çünkü, kredi verileri genellikle normal dağılımda değildir ve kategoriktir (Bolton, 2009).

Bir diğer yöntem olan lojistik regresyon analizin, açıklanması ve uygulaması kolay modeller üretmesi nedeniyle (Bolton, 2009) bu alanın temel taşlarından biri olma özelliğini korumaktadır. Günümüzde sayıca fazla ve popüler kredi skorlama modelleri bulunmasına rağmen çoğu kuruluş tarafından ana model olarak kullanılmaya devam etmektedir. Özellikle banka sektöründeki düzenleme çerçeveleri kapsamında kurumların içsel

derecelendirmelerinden beklenen koşulların denetleyicilere aktarılmasında sağladığı kolaylık sebebiyle makine öğrenimi modelleri yerine tercih edilmektedir (Runchi vd., 2023). Çünkü, model parametrelerinin tahmin etme uygulamaları kapsamında detaylı bilgi verilmesi gereken düzenleyicilere, genellikle ‘kara kutu’ yapısında olan ve açıklanmaları kolay olmayan makine öğrenimi modelleri süreci zorlaştırmaktadır (Dumitrescu vd., 2022).

Lojistik regresyon analizi, bağımsız değişkenlerin normal dağılımda olması, eşit varyansa sahip olması ya da doğrusal ilişki içerisinde olmasını gerektirmez (Stella, 2019). Ancak, sınıflandırmanın başarılı olabilmesi için verilerin eksiksiz olması gerekir (Ptak-Chmielewska, 2016). Bu nedenle, verilerin boyut ve büyüklüğünün hızla arttığı günümüzde lojistik regresyon analizi, ortaya çıkan örneklem dengesizlikleri ile baş etmekte zorlanabilir (Brown ve Mues, 2012). Bununla birlikte çoklu doğrusallığa da duyarlıdır (Douplos ve Zopoudinis, 1999).

Probit model, logit yönteminin başarılı bir alternatifi olup, aralarındaki temel fark bağımsız değişkenlerin normal dağılımına ait varsayımdır (Klieštik vd., 2015). Bu nedenle, lojistik regresyona göre daha az esnektir (Hahn ve Soyer, 2005). Örneklemin aşırı gözlem içermediği varsayılırsa uygulamada aralarında pek fark yoktur (Klieštik vd., 2015). Ayırma analizindeki varsayım sorunlarını da giderebilir olsa da fazla hesaplama gerektirdiğinden çok tercih edilmemektedir (Dimitras vd., 1996).

Lojistik regresyon ve probit gibi parametrik modellerde, bağımsız değişken ve bağımlı değişken arasındaki ilişkinin anlaşılması ve yorumlanması kolay olup (Abdel-Aty ve Abdelwahab, 2004) yüksek tahmin doğruluğu sağlama yetenekleri nedeniyle faydalıdır (Weng vd., 2013). Ancak, ön varsayımlarının olması model sonuçlarını olumsuz etkileyebilir ve gizli etkiler sorunu nedeniyle risk faktörleri farklı durumlardan etkilenebilir (Ghasemzadeh ve Ahmed, 2019).

Gerçek hayatta, temerrüt olasılığının finansal rasyo değerleri ile doğrusal bir ilişki bulunmaz. Bu durum, temerrüt riski çalışmalarında doğrusal olasılık modeli kullanılması halinde değişimin katkısının hep aynı kalması nedeniyle sorun oluşturur. Ancak, probit ve logit modeller temerrüt olasılığının 0 ve 1 değerleri arasında kalmasını sağlayarak bu sorunu giderirler (Mirza, 2006).

Literatür çalışmalarında lojistik regresyon, ayırma analizi ve diğer regresyon türleri gibi geleneksel tekniklerin kullanımı son zamanlarda azalmışken, topluluk ve hibrit yaklaşımlar gibi yeni yöntemlerin kullanımı hızla artmıştır (Çallı ve Coşkun, 2021).

Sonraki bölümde, çalışma kapsamında incelenen istatistiksel yöntemlere literatürde yer verilmiştir.

3.3.1.2. Literatür Taraması

Kredi riski alanındaki ilk çalışmalar finansal başarısızlık kapsamındaki tahminlere ve bu başarısızlığa etki eden faktörlerin tespit edilmesine yönelik olmuştur. Bu çalışmalarda genellikle firmaların mali verilerinden elde edilen finansal oranlardan yararlanılmıştır. İlerleyen çalışmalar, yeni analizler, farklı metotlar ve hibrit yöntemlerin geliştirilmesini sağlamıştır. Küçük ve orta ölçekli işletmelerin değerlendirilmesinin ayrı çalışmalar gerektiği ve piyasa fiyatlamalarının modellere dâhil edildiğine ilişkin tespitler yapılmıştır. Gelineen noktada veri madenciliği teknikleri ve farklı modeller ile karşılaştırmalar ve geliştirmeler devam etmektedir.

i. Yurt Dışı Çalışmalar

Ayırma analizi, lojistik regresyon ve probit yöntemlerinin ele alındığı yurt dışı çalışmalar genel olarak kredi riski analizinde en iyi olarak nitelendirilebilecek tek bir yöntemin olmadığını belirtmektedir. Yöntemlerdeki istatistiksel varsayımların getirdiği kısıtlamaları ve sorunları aşabilmek için alternatif yöntemlerinin kullanılmasının faydalı olacağı ve hibrit yöntemlerin gelecek çalışmalar için önemli olduğu vurgulanmıştır. Kredi veri setlerinin genellikle dengesiz dağılıma sahip olması ve kötü kredi olarak adlandırılacak borçluların verilerindeki eksikliklerin hatalı tahmine yol açtığı belirtilmiştir. Sınıflandırma hatalarını minimize etmeye odaklanan çalışmalar, iflas riskinin tahminlenmesi kadar elde edilebilecek kârın da oldukça önemli olduğunun altını çizmektedir. Çalışmalarda genellikle kullanılan mali tablo verilerinin yanı sıra finansal olmayan verilerin modellerin tahmin gücünü arttırabileceği belirtilmiştir.

Tablo 3.3. Geleneksel Yöntemler Yurt Dışı Literatür Taraması

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Risk Elements in Consumer Instalment Financing</i>	David Durand	1941	Kredi Kararına Etki Eden Faktörlerin İncelenmesi, Tüketici Kredisi Temerrüt Riski ve Kredi Skolama Ticari ve Endüstriyel Bankalar, Kişisel Finans Şirketleri, Otomobil ve Cihaz Finans Şirketleri	Doğrusal Ayırma Analizi
SONUÇ/BULGU	Çalışmada, kredi görevlileri tarafından önemli kabul edilen risk faktörlerinin önemi ampirik olarak analiz edilmiş ve gelecekteki tahminleme çalışması için kullanımı amaçlanmıştır. Kredi başvuru sahibinin niteliklerine göre belirlenen değişkenler kredinin iyi ya da kötü olarak belirlenmesinde kullanılmıştır. Geliştirilen etkinlik indeksi kredi faktörlerinin gelecekteki risk seçimindeki potansiyel önemini ölçer. Peşinat tutarının etkili risk faktörü olduğu tespit edilmiştir. Gelir seviyesi yüksek grupların, düşük gruplara göre orta derecede daha iyi risk taşıdığı görülmüştür. Tüketicilere ait gelir seviyesinin yüksek olmasının, başvurunun iyi bir risk sınıfına ait olduğunu gösteren en belirgin grup kişisel finans şirketleri olmuştur. Bankalarda borçlanma miktarı dikkate alınmadığı takdirde gelir seviyesinin çelişkili sonuçlar ürettiği görülmüştür. Ayrıca, daha fazla çalışmaya ihtiyaç olduğu vurgulanmıştır. Çalışmada, yaşın risk tecrübesi ile çok belirgin bir olmayan bir ilişkisi olmakla birlikte yaşlı adayların gençlere göre daha iyi risk grubunda olduğu görülmüştür. Kadınların erkeklerden daha iyi risk grubunda olduğu görülmüştür. İstihdam ve ikametgâh istikrarının borç verenin risk maruziyetinin belirlenmesinde önemli olduğu sonucuna ulaşılmıştır. Kredi derecelendirme formülü, kredi başvurularını değerlendirmede çalışmadaki farklı şirketlere uygulanmıştır.			
<i>Measuring Risk on Consumer Instalment Credit</i>	Paul F. Smith	1964	Kredi Skolama ve Temerrüt Riski Banka Tüketici Kredileri Kredi Başvurusu	Doğrusal Ayırma Analizi
SONUÇ/BULGU	Çalışma, kredi reddetme çıkarımı için yöntem önerisinde bulunmuştur. Doğrusal ayırma analizi, belirlenen karakteristik niteliklere göre kredibilite ölçümü için kullanılmıştır (Bierman ve Hausman, 1970). Geliştirilen risk indeksi tekniği ile kişisel özelliklerin bir listesi oluşturulmuştur ve Bayes teoremi ile her biri için kötü hesap olasılığı hesaplanmıştır (Galitz, 1983). İlgili olasılıklar, kredi başvuru değerlendirmelerinde göz önüne alınarak başvuru sahibinin kredibilitesini gösterir şekilde ağırlıklandırılmıştır. Genel bir risk indeksi vermek üzere toplanan bu değerin yüksek olması halinde temerrüt riski de artmaktadır (Galitz, 1983). Ayrıca, yaş, cinsiyet ve evlilik durumunun ödeme performansı ile ilişkili olduğu bulunmuştur. Böylelikle, kredi başvuru değerlendirmelerinin maliyeti azaltılabileceği ve kredinin kalitesinin ölçümü ve kontrolünün sağlanabileceği sonucuna ulaşılmıştır.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Financial Ratios as Predictors of Failure</i>	William H. Beaver	1966	Kurumsal Kredi Riski / Finansal Başarısızlık, İflas Tahmini Moody's Manual Firmaları (Özel Şirketler, Kurumsal Olmayan Firmalar, Sınai Dışı Firmalar Hariç; Kamu Kurumları, Ulaştırma Şirketleri ve Finansal Hizmetler Hariç Gibi)	Doğrusal Ayırma Analizi, Tek Rasyo
SONUÇ/BULGU	Çalışma ile finansal oranların finansal başarısızlık tahmininde kullanılmasının faydalı olduğu, tek değişkenli bir modelde ampirik olarak kanıtlanmıştır. 30 adet finansal oranın her biri incelenmiş ve Nakit Akış / Toplam Borç oranı başta olmak üzere sırasıyla korelasyonu en yüksek olan Aktif Kârlılık (Net Gelir / Toplam Varlıklar) ile Toplam Borçlar / Toplam Varlıklar oranlarının iflas tahminlemede en başarılı tahminler olduğu bulunmuştur. Nakit Akış / Toplam Borç Oranının iflastan bir yıl öncesinde tahminleme hatası %13 iken beş yıl öncesinde %22 olduğu belirtilmiştir. Başarısızlık beklentisinin %50 civarında olması beklenirken beklentiden daha iyi gelen oranlar gelmesi oran bileşenlerinin davranışlarının analiz edilmesi ile incelenebilir. Burada en kritik faktör, en önemli faktör olan rezervleri besleyen likit varlık akışıdır. Bu faktörler büyüdükçe iflas riski olasılığı azalırken; borçlar ve gider hesaplarının büyümesi iflas riski olasılığını arttırmaktadır. Birkaç farklı oran ya da oranların zaman içerisindeki değişimi gözlemleyen çoklu oran analizinin daha iyi tahminlerde bulunacağı öngörülmüştür.			
<i>Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy</i>	Edward I. Altman	1968	Kurumsal Kredi Riski / İflas Tahmini İmalat Firmaları	Çoklu Ayırma Analizi (MDA)
SONUÇ/BULGU	Çalışmada finansal oranların kombinasyonunu incelenmek için tek değişkenli model yerine çoklu ayırma analizi kullanılmıştır. Ayrıca, çoklu ayırma analizini temel alan Z skoru modeli geliştirilmiştir. Firmanın, Z skorunun 1,8'in altında olması mali olarak sıkıntılı, 2,99 üzerinde olması sağlıklı olduğu ve bu değerler arasında bir değer iflas tahmin ön görüşünü zorlaştıran bir gri alan olduğu ileri sürülmüştür. Model kârlı ya da sıkıntı işaretleri gösteren firmaları tespit etmede başarılıdır. İflas eden ve etmeyen firmaların doğru sınıflandırma seviyesi yüksek çıkmıştır. Modelin tüm firmalar için tahmin gücü Tip II hataya göre %79'dur. Tüm firmalar için sınıflandırma doğruluğu %95'tir. Kullanılan 6 değişken ile tahminleme gerçek iflas öncesindeki ikinci yıla kadar başarılıdır. Çalışmanın bulgusuna göre finansal bilgiler, kullanılan yöntem ve geliştirilen model firmaların iflas tahminlemede etkili bir araçtır.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>A Discriminant Analysis of Predictors of Business Failure</i>	Edward B. Deakin	1972	Kurumsal Kredi Riski / İflas Tahmini Moody's Manual Firmaları (Özel Şirketler, Kurumsal Olmayan Firmalar, Sınai Dışı Firmalar Hariç)	Çoklu Ayırma Analizi (MDA)
SONUÇ/BULGU	İflas tahmininin bir yıldan daha uzun bir süre için yapılması adına alternatif bir yöntem önerilmiştir. İflastan önceki beş yılın her biri için ayırma modeli kullanılmıştır. Her bir ayırma fonksiyonunun önemini test etmek için wilk's lambdadan yararlanılmıştır. Kullanılan 14 rasyo için iflaslardan bir yıl öncesinde modelin hata oranı %22, iki yıl öncesinde %6, üç yıl öncesinde %12, 4 yıl öncesinde %23 ve 5 yıl öncesinde %15'tir. İlk yıl haricindeki diğer yıllarda hata oranını Beaver (1966)'a göre iyileştirmiştir. Üç yıl öncesine kadar iflas tahminleri yüksek bir doğruluk oranı ile yapılabilir. Test setinde modelin iflas tahmin gücü iki yıl öncesi için %96'dır. Ayrıca, modelin uygulandığı popülasyon büyüklüğü sebebiyle dış geçerliliğini arttırmak için çalışmalar yapılması gerektiği vurgulanmıştır.			
<i>Financial Ratios and The Probability Prediction of Bankruptcy</i>	James A. Ohlson	1980	Kurumsal Kredi Riski/İflas Tahmini Endüstriyel Firmalar (Kamu Kurumları, Ulaştırma Şirketleri ve Finansal Hizmetler Hariç) (Moody's Manual, S&P, Stanford University Business School Library, Wall Street Journal Index (W.S.J.I.))	Lojistik Regresyon (Koşullu logit modeli)
SONUÇ/BULGU	Çalışma ile O-skoru modeli geliştirilmiştir. Koşullu logit modelin, çoklu ayırma analizindeki kısıtlayıcı sorunları engellediği belirtilmektedir. Önceki çalışmalardan farklı olarak, çalışmada kullanılan firmaların iflas ve son mali bilgilerine ait raporların yayım tarihlerine dikkate alındığı belirtilmiştir. Firmanın büyüklüğünün yanında mali yapısı, performans ve likidite ölçümlerinin finansal başarısızlık olasılığının bir yıl içerisindeki başarısızlık değerlendirilmesinde istatistiksel olarak anlamlıdır. Model, firmaların iki yıl içerisinde iflas riski O-skoru ile 0,38 olarak tanımlandığında %96 doğruluk ile sınıflandırmıştır. İlerleyen çalışmalar için muhasebe hesaplarından türetilen finansal oranlar dışında piyasa verileri de kullanılarak değişkenlerin genişletilmesi gerekliliğine değinilmiştir.			
<i>Probit and Discriminant Functions for Classifying Credit Applicants: A Comparison</i>	B. J. Grablowsky ve W. K. Talley	1981	Kredi Riski Skorlama Perakende Zinciri Kredi Başvurusu	Çoklu Ayırma Analizi (MDA) ve Probit Model
SONUÇ/BULGU	Probit modeli iyi risklerin %91'ini ve kötü risklerin %93'ünü doğru bir şekilde sınıflandırırken; çoklu ayırma analizi, iyi risklerin %100'ünü ve kötü risklerin %80'nini doğru sınıflandırmıştır. Bu sonuçlar, farklı hata tiplerinin beklenen kâr ve göreceli maliyetleri arasındaki dengeyi göstermektedir (Clarke ve McDonald, 1992). Ayrıca, katsayıların benzersizliğini ve çoklu bağlantı etkisini test etmiş ve probit modelin ayırma analizine alternatif olabileceği sonucunu bulunmuştur (Dimitras vd.,1996).			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Methodological Issues Related to The Estimation of Financial Distress Prediction Models</i>	Mark E. Zmijewski	1984	Kurumsal Kredi Riski / İflas Tahmini Amerika ve İngiliz Borsası'nda Yer Alan Firmalar (Endüstri Kodu 6000'Den Küçük Olanlar)	Probit Model
SONUÇ/BULGU	Çalışma, mali sıkıntı tahmin modellerinde, rastgele olmayan örneklem kullanılmasıyla yanlış parametre ve sonuçlara sebep olduğunu belirtmiştir. 1966 ve 1983 yılları arasında mali sorunlara yönelik araştırma yapan 17 adet çalışmanın örneklem seçimi ve veri toplama prosedürlerini incelenmiştir. Çalışmada, mali sıkıntı yaşayan firmaların oranının düşük olması ve bu firmalara ilişkin verilerin çoğunlukla olmaması nedeniyle oluşan hatalar değerlendirilmiştir. Örneklem, bağımlı değişkenin özelliklerine göre seçilmesinin seçime dayalı örnek yanlılığı ile taraflı sonuçlara yol açtığı tespit edilmiştir. Örneklem seçim yanlılığının yalnızca tam veriye sahip firmaların analiz edilmesinde gerçekleştiği belirtilmiştir. Ancak, çalışma sonucunda sınıflandırma ve tahmin oranlarının büyük ölçüde etkilenmediği görülmüştür. Bu nedenle, veri kalitesi ve veri temizleme işlemlerinin önemi vurgulanmıştır. Çalışmada, iflas olasılığını tahmin etmek için daha sağlam bir çerçeve sağlamak ve sınıflandırma oranlarının ve tahmin performansının iyileşmesine yol açmak için çalışmada WESML tekniği kullanılmıştır. Bu teknik ile %2,6 ile %3,2 arasında çıkan sonuçlar, ağırlıklandırılmamış probit modele göre daha düşüktür. Çalışma sonucunda, doğru sınıflandırılmış iflas eden firmaların yüzdesi ile tahmin örneklemine frekans oranı arasındaki korelasyon katsayısı %94,9 oranı ile güçlü bir ilişki olduğu bulunmuştur.			
<i>A Linear Programming Alternative to Discriminant Analysis in Credit Scoring</i>	William E. Hardy ve John I. Adrian	1985	Kredi Riski Skoru, New Orleans Federal Arazi Bankası Tarım Kredisi Hesapları (Federal Land Bank)	Ayırma Analizi ve Doğrusal Programlama
SONUÇ/BULGU	Ayırma analizi 0,32 sonlanım noktasında toplam örneklemi %70,6 oranında doğru sınıflandırmıştır. Ayırma analizi iyi durumda olan kredileri %71,2 oranında doğru sınıflandırmıştır. Doğrusal programlama %74,8 oranında başarı göstermiştir. Burada, doğrusal programlamaya göre 64 ek borçluya daha kredi verilebileceği bulundu. Ancak, ayırma analizi kötü kredileri %67,5 oranları ile sınıflarını doğru değerlendirirken; doğrusal programlamada %35,7 seviyesinde kalmıştır. Doğrusal programlama, sorunlu kredileri kabul edilebilir olarak sınıflandırması, iyi kredi verme kararlarındaki başarısını geri planda bırakmaktadır. Doğrusal programlama, kullanıcılarına yüksek düzeyde istatistik bilgi olmadan analiz ve yorumlamaya izin vermektedir. Hatalı sınıflandırma ağırlıklarını değiştirebilme yeteneği vardır. Çalışma bulgusuna göre doğrusal programlama kredi skorlama modellerinde kullanılabilecek alternatif bir yöntemdir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>An Econometric Analysis of The Bank Credit Scoring Problem</i>	William J. Boyes, Dennis L. Hoffman ve Stuart A. Low	1989	Kredi Riski Skorumla Banka Kredi Kartları Kredi Başvurusu	İki Değişkenli Probit, WESML
SONUÇ/BULGU	Çalışma, kredi başvurularını değerlendirmek için yapılan çalışmalardaki örneklemelere ait verilerin başvurusu kabul edilmiş olanlardan oluştuğunu tespit etmiş ve bu yanlılığın önüne geçmek için iki değişkenli probit modeli önermiştir. Bu iki bağımlı değişkenin ilki kredi başvuru kararı ve diğeri de temerrüt durumudur. Temerrüt olasılığının tahmini için Manski-Lerman WESML tekniği kullanılmıştır. Modele uygulandığında popülasyonun, %48,4'ü iyi, %2,6 'kötü' ve %49'unun reddedilen olduğu anlamına gelmiştir. Kredi verme kriterine göre temerrüt olasılığı %9'un altında olan başvuruların beklenen kazanca sahip olduğu bulunmuştur. Literatürde uygulanan kredi skorumla modellerinin iyi ve kötü kredi sınıflandırma hatalarını en aza indirme çabasında olduğu belirtilmiştir. Borç verenin esas amacı kârlılık olduğundan dolayı esasen her başvuran için temerrüt olasılığına, geri ödeme durumuna ve gerçekleşecek ödemelerinde doğru tahminler yapılmasının daha geniş bakış açısı sunacağı vurgulanmıştır. Bu nedenle, bu parametreler üzerinden en iyi faydayı sağlayan bir kriter belirlenebileceği belirtilmiştir. Kredi kartı kullanıcılarının temerrüde düşme süresindeki tahminlerin iyileşmesinin beklenen kazançların ölçüm yeteneğini arttıracığı belirtilmiştir.			
<i>Bankruptcy Prediction Using Case-Based Reasoning, Neural Networks, and Discriminant Analysis</i>	Hongkyu Jo, Ingoo Han ve Hoonyoung lee	1997	Kurumsal Kredi Riski /İflas Tahmini Kore Firmaları	Doğrusal Ayırma Analizi, Vaka Bazlı Tahminleme (CBFS), Sinir Ağları
SONUÇ/BULGU	Çalışmaya göre, iflas tahmininde sinir ağları yöntemi, çoklu doğrusal ayırma analizi ve vaka bazlı tahminlemeye kıyasla daha başarılı olup en iyi performansı göstermiştir. Tüm test setleri için modellerin ortalama başarı oranı sırasıyla; sinir ağları %83,79, doğrusal ayırma analizi %82,22 ve vaka bazlı tahminleme için %81,52'dir. Bu çalışmada vaka bazlı tahminleme tekniği, iflas tahminine uygun olmadığı sonucuna ulaşılmıştır. Gelecekteki araştırmalar için hibrit bir sistem geliştirmenin olacağı belirtilmiştir.			
<i>Statistical Classification Methods in Consumer Credit Scoring: A Review</i>	D.J. Hand ve W.E.Henley	1997	Kredi Riski İstatiksel Yöntemler Literatür İncelemesi (Model ve Veri Setleri) Finansal Kurumlar Tüketici Kredileri	Doğrusal Ayırma Analizi, Regresyon, Lojistik Regresyon, Matematiksel Programlama Metotları, Karar Ağaçları, Uzman Sistemler, Sinir Ağları
SONUÇ/BULGU	Çalışmada, tüketici kredilerindeki önemli büyüme nedeniyle kredi puanlamanın ve değerlendirmelerin doğruluğunu artırmanın önemine vurgu yapılmış ve istatistiksel yöntemlerin kritik bir rol oynadığı belirtilmiştir. Kredi skorumlardaki örneklemelerin önceden iyi riskli olarak sınıflandırılan borçlulardan oluştuğu için reddedilen başvurular hakkında bilgi eksikliğine yol açtığı belirtilmiştir. Kredi skorumla modellerinin amacının yalnızca iflas riskini azaltmak olmadığını aynı zamanda kârlılığı arttırmak olduğuna değinilmiştir. Yöntemin ele aldığı soruna göre uygulanan metotların başarısının değişebileceği ve bu nedenle en iyi olarak nitelendirilecek bir yöntemin olmadığı belirtilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Credit Scoring Using The Hybrid Neural Discriminant Technique</i>	Tian-Shyug Lee, Chih-Chou Chiu, Chi-Jie Lu ve I-Fei Chen	2002	Kredi Riski Skolama Banka Kredi Kartları	Hibrit Sinirsel Ayırma Modeli, Ayırma Analizi, Lojistik Regresyon, Sinir Ağları
SONUÇ/BULGU	Çalışmanın sonuçlarına göre, ayırma analizi %71,40, Lojistik regresyon %73,45 doğru sınıflandırma oranlarına göre sinir ağları %73,70 ile en yüksek performansa sahiptir. Sinir ağlarında model hesaplama süresi uzun olsa da genelleme ve diğer güçlü yönleri ile kredi skorlamada popüler hale gelmektedir. Uygulanan hibrit sinirsel ayırma modelinin ortalama doğru sınıflandırma oranı %77 olup; Tip II hata performansı diğerlerine göre daha düşük hatalı sınıflandırma maliyetine sahiptir. Çalışmada, sinir ağlarının yayılımı doğrusal ayırma analizi ile birleştirilerek hibrit bir model oluşturulmuştur.			
<i>An Emerging Market Credit Scoring System for Corporate Bonds</i>	Edward I. Altman	2005	Kurumsal Kredi Riski Skolama ve Temerrüt Riski Yükselen Piyasa Ekonomileri ve Şirket Tahvilleri	Çoklu Ayırma Analizi (MDA) / (Z skoru, EMS modeli)
SONUÇ/BULGU	Çalışmada geliştirilen EMS modelinin temelinde Z skoru modeli baz alınmıştır. Gelişmekte olan ülkelere, Amerikan modelini uygulayabilmek için dövizdeki devalüasyon kırılganlığına göre tahvil notlarında düzeltme yapılmıştır. Model, Meksika'nın peso krizi ele alınarak değerlendirildiğinde temerrüt durumlarının tamamını doğru tahmin etmiştir. Brezilya ve Arjantin gibi diğer ülkelere uygulandığı belirtilen modelin, bu ülkeler için de başarılı olduğu ancak ilgili ülkelerin kendi değerlendirme modellerini geliştirmeleri gerektiği belirtilmiştir.			
<i>Modelling Credit Risk for SMEs: Evidence from the U.S. Market</i>	Edward I. Altman ve Gabriele Sabato	2007	Kurumsal Kredi Riski Amerika Piyasasındaki Küçük ve Orta Ölçekli İşletmeler	Lojistik Regresyon, Çoklu Ayırma Analizi (MDA)
SONUÇ/BULGU	Çalışma, ekonomik ölçekte oldukça önemli bir yer tutan küçük ve orta ölçekli işletmeler (KOBİ) kapsamında yapılmıştır. Bu firmaların, OECD ülkelerindeki firmaların %97'sini ve Amerikan ekonomisindeki iş gücünün %75'ini oluşturduğu belirtilmiştir. Literatür finansal olmayan verilerin modelin tahmin gücünü arttırdığı belirtilse de veri tabanında bu bilgiler yer almadığı için finansal oranlar üzerinden ilerlenmiştir. Çalışma sonucunda, çoklu ayırma analizinin temerrüt tahmin performansı uygulanan lojistik modellere göre daha düşük olduğu bulunmuştur.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Performance Comparison of Multiple Discriminant Analysis and Logit Models in Bankruptcy Prediction</i>	Matúš Mihalovič	2016	Kurumsal Kredi Riski /İflas Tahmini Slovak Cumhuriyeti Seçilen Firmalar	Çoklu Ayırma Analizi (MDA) ve Lojistik Regresyon
SONUÇ/BULGU	Çalışmaya göre, finansal oranlar içerisinde normal dağılıma sahip olan tek oran İşletme Sermayesi/Toplam Varlık'tır. Çalışmada, modele dahil edilen her değişkenin istatistiksel olarak anlamlı olduğuna dikkat edilmesi gerektiği belirtilmiştir. Dönen Varlıklar/Toplam Varlıklar oranının anlamlı olmadığı başka bir ifadeyle iflas tahminlemedeki ayrımı iyi yapmadığı görülmüştür. Cari oran negatif anlamda en iyi ayırıcı olduğu tespit edilmiştir. Cari oran yüksekse iflas riski düşüktür. Çalışma sonucuna göre, çoklu ayırma analizi çoklu doğrusallık, aykırı değerlerin varlığı, oran değerlerinin normal olmaması gibi kısıtlamaları sebebiyle iflas tahmininde kullanılması önerilmemiştir. Logit modelin tahminleme yeteneği yetersiz bulunmuştur. Eğri altında kalan alan (AUC) değerlerine göre logit model %77,2 ve ayırma analizi %72,3 olasılıkla doğru sınıflandıracaktır. Çalışmanın sonucuna göre istatistiksel varsayım ve sınırlılıkları gerektirmeyen yapay zekâ uzman sistemlerinin ve diğer tekniklerin kullanılması gerekmektedir.			

Kaynak: Yazar tarafından oluşturulmuştur.

ii. Yurt İçi Çalışmalar

Ayırma analizi, lojistik regresyon ve probit yöntemlerin ele alındığı yurt içi çalışmalarda genel olarak mali tablo verilerinin temerrüt riski ile ilişkili olduğu ve her bir kredi başvurusunda dikkate alınması gerektiği belirtilmiştir. Net satışlar, toplam borçlar, ticari alacaklar, banka ve stok mali verilerinin kullanıldığı değişkenlerin modellerde etkili olduğu görülmektedir. Sanayi üretim endeksi ile takipteki alacakların negatif ilişkisi olduğu belirtmektedir. Kredi başvurularında birden fazla yöntem ve model kullanımının daha etkili olacağının altını çizmektedir.

Tablo 3.4. Geleneksel Yöntemler Yurt İçi Literatür Taraması

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOD
<i>Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırılması</i>	Ramazan Aktaş, Mete Doğanay, Birol Yıldız	2003	Kurumsal Kredi Riski / Finansal Başarısızlık SPK'ya Tabi ve/veya İstanbul Menkul Kıymetler Borsası'nda (İMKB) İşlem Gören Sanayi, Ticaret ve Hizmet İşletmeleri	Çoklu Regresyon Modeli, Doğrusal Ayırma Analizi, Logit Model ve Yapay Sinir Ağları
SONUÇ/BULGU	Çalışmada, likidite ve kârlılık mali başarıyı olumlu yönde etkilerken; dış kaynak kullanımı olumsuz etkilemiştir. Çalışmadaki modellerin genel öngörü gücü; çoklu regresyon %89, doğrusal ayırma analizi %87 ve logit model %90'dır. Ancak, performansına karşın logit modelinde sonuçlarında taşıdığı yanlışlık nedeniyle, başarısız işletmeleri tahmin etme maliyeti yüksektir. Bu nedenle diğer iki yönteme kıyasla tercih edilebilirliğini olumsuz etkilenmektedir. Yapay sinir ağları modelinin genel öngörü gücü %95,71'dir ve doğru ön görüşü gücü en yüksek modeldir. Ayrıca, çalışma kontrol grubu üzerinde daha iyi sonuç verdiği belirtilmiştir.			
<i>Türkiye'de Ödeyememe Riskinin Ölçülmesine Ekonometrik Bir Yaklaşım</i>	Mehmet Salman	2004	Temerrüt Riski İMKB Firmaları (Finansal Kuruluşlar Hariç)	Probit Model ve Lineer Regresyon (Z skoru ve O skoru)
SONUÇ/BULGU	Çalışmada, Z skoru modeli, toplam hata oranı %15,39 ile en iyi performansı gösterirken O Skor modeli %19,19 hata oranı ile en düşük performansı gösteren model olmuştur. Z ve O skorlarının Tip I hataları %14,29 oranı ile aynı iken Tip II hata oranında %16,49, Z skoru ve %24,09 O skor oranı ile ayrılmışlardır. Çalışmada temerrüt riskinde önemli görülen rasyoların performansları da analiz edilmiş ve Türkiye için Net Satışlar / Toplam Varlıklar, Özsermaye / Toplam Borçlar, Toplam Borçlar / Toplam Varlıklar, Kısa Vadeli Borçlar / Dönen Varlıklar, Toplam Finansal Borçlar / Toplam Varlıklar ve Dönem Net Karı / Net Satışlar değişkenlerinin ödeyememe riskinin ölçülmesinde kullanılması tavsiye edilmiştir.			
<i>Kredi Kartı Değerlendirme Tekniklerinin Karşılaştırılması</i>	Murat Çinko	2006	Tüketici Kredi Riski Finans Kurumu Kredi Kartı Başvurusu	Doğrusal Ayırma Analizi, Lojistik Regresyon, Sınıflama ve Regresyon Ağacı ve Yapay Sinir Ağları
SONUÇ/BULGU	Çalışmada, farklı ölçütlere göre kullanılan yöntemlerin başarısı değişmektedir. Doğru sınıflandırma ve Tip I hatada en iyi model karar ağaçları iken Tip II hatada en iyi model yapay sinir ağları olmuştur. Doğrusal ayırma analizi Tip I hatada yapay sinir ağlarından sonra en iyi performansı gösterirken; Tip II hatada son sırada yer almaktadır. Lojistik regresyon toplam doğru sınıflandırma başarısında ikinci sıradadır. Artan kredi kartı başvurularının değerlendirilmesi için farklı yöntemler ile birden fazla model kullanılabilir. Böylelikle, çelişkili sonuçlarda daha doğru karar alınabileceği sonucuna varılmıştır.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOD
<i>Bankaların Kredi Dönüşlerinin Erken Uyarı Modeli ile İncelenmesi</i>	Raziye Kaya	2008	Banka Ticari Kredi Temerrüt Riski	Lojistik Regresyon
SONUÇ/BULGU	Çalışmada, önceki çalışmalardan farklı olarak finansal oranlar yerine bilanço kalemlerine esas tutarlardan faydalanılmıştır. Bağımsız değişkenin farklı dönem ya da dönem ortalamalarına göre olan 5 farklı model oluşturulmuştur. Değişkenler olasılık değerine göre modellere dahil edilmiş ya da çıkarılmıştır. En güvenilir sonuçlar 2004-2005 yılları arasındaki verilerin ortalamalarının alındığı, bilançonun aktif tarafında yer alan banka, ticari alacaklar ve stoklar değişkenleri ile oluşturulmuş modeldir. Çalışma bulgusu, daha önce çalışılmış firmalardan yeni bir kredi talebi geldiğinde mali ve finansal verileri dikkate alınarak ilk başvuru gibi değerlendirilmesi gerektiğidir. Diğer bir bulgu ise firmaların grup firması olmasının ya da teminat yapısının önemli olmayışdır.			
<i>Determinants of the Credit Risk in Developing Countries After Economic Crisis: A Case of Turkish Banking Sector</i>	Serhat Yüksel	2017	Kredi Riskinin Belirleyici Faktörleri, Türkiye Mevduat Bankaları	Probit Model
SONUÇ/BULGU	Çalışmada, takipteki alacakların ana değişken olarak yer aldığı modelde 9 adet değişken kullanılmıştır. Bunlardan dördü işsizlik gibi dış değişkenlerdir. Çoklu doğrusallık sorunu nedeniyle bazı değişkenler modelden çıkarılmıştır. Modelin sonucuna göre sanayi üretim endeksi ile takipteki krediler arasında negatif ilişki olduğu belirtilmiştir. Üretim çıktısının arttığında takipteki kredilerde düşüş gözlemlenmektedir. Ayrıca, üretim miktarının düşüşü nedeniyle firmalar kapanabilir ya da işten çıkarmalar yaşanabilir. Bu da işsizliğin artmasına ve ekonomik durgunluğa yol açar. Bu durumdan etkilenen firma ve kişiler borçlarını ödeyemeyecekleri için takipteki kredilerde artış görülecektir.			
<i>Bankacılık Sektöründe Kredi Risk Yönetimi ve Bir Tahmin Modeli Örneği</i>	Selim Duman, Sibel Yılmaz Türkmen	2023	Banka Kredi Riski İmalat Sanayi Sektörü Firmaları	Lojistik Regresyon
SONUÇ/BULGU	Çalışma bulgularına göre Toplam Mali Borçlar / Net Satışlar ve Toplam Ticari Borçlar / Pasif Toplamı oranlarının artması temerrüt riski olasılığını artırırken; Duran Varlıklar / Aktif Toplamı ve Faaliyet Karı / Net Satışlar oranının artması temerrüt riski olasılığını azaltmaktadır. Modelin, doğru sınıflandırma başarısı %73,3 ve test örnekleminde finansal başarısızlıktan 1 yıl öncesinde %66,7 oranında doğru sınıflandırma yapılmıştır.			

Kaynak: Yazar tarafından oluşturulmuştur.

Kredi risk analizlerinde kullanılan istatistiksel yöntemlerin kısıtlamaları çalışmaların yönünü yeni yöntemlere yöneltmiştir. Veri hacmindeki artış, veri kalitesini ve model performanslarının hızını daha önemli hale getirmiştir. Bu nedenle, kredi riski değerlendirmeleri

insan beyninin düşünme sürecini simüle eden yapay zekâ ile birleştirilmiştir (Xu vd., 2019). Bu modeller, verileri optimize eden algoritmalar ile anında ve dinamik olarak işlemektedir (Xu vd., 2019). Bu kapsamda, makine öğrenmesi kavramına, önemine ve kredi riski değerlendirmelerinde kullanılan metotlarına değinilecektir.

3.3.2. Makine Öğrenmesi

Yapay zekânın bir parçası olan makine öğrenmesi, insan müdahalesini en aza indirgeyerek analitik model oluşturmayı otomatikleştiren bir sistem olarak tanımlanabilir (Wang vd., 2020). Kökeni 1940'lı yıllara kadar uzanmakla birlikte son birkaç on yılda, makine öğrenmesi algoritmalarının alt yapısını destekleyen teknolojilerin ilerlemesi; yeni veri depolama seçenekleri ve hızlanan veri işleme kapasiteleri ile popüler hale gelmiştir (Escobar, b.t.).

Kazandığı hızlı ivme sayesinde dünya genelinde birçok farklı alanda kullanılmaktadır (Shoumo vd., 2019). Özellikle, günümüzün finansal ekosisteminin tamamlayıcısı olarak önemli bir rol oynamaktadır (Al Mazrouei ve Nobanee, 2020). Çünkü gelişen finans sektöründe etkili risk yönetimi ve tahminlerin doğruluğu oldukça önemlidir. Makine öğrenmesi tekniklerinin de geniş veri kümeleri ile çalışması, anomalileri tespit etmesi, uyum yeteneği ve gelişen algoritma ve teknikleri, bilinçli karar alma ve risklerin proaktif yönetiminde onu etkili bir uygulama alanı haline getirmektedir (Wang vd., 2020; Oroy ve Evan, 2024). Müşteri analitiği, piyasa eğilimleri ve ekonomik veriler açısından ürettiği bilgiler ile finans alanındaki rolü artmaya devam edecek ve sektörün geleceğini şekillendirip inovasyonu teşvik edecektir.


Son dönemlerde takipteki alacakların ve dolandırıcılık işlemlerinin artışı kredi riskini önemli ölçüde arttırmaktadır (Bhatore vd., 2020). Bu durum, kredi onay süreçlerinde, müşterilerin ödeme davranışları ile diğer eğilimlerin izlenmesinde (Faggella, 2019; akt. Al Mazrouei ve Nobanee, 2020) ve risk değerlendirmelerinin doğruluğunun artırılmasında makine öğrenmesi teknikleri önemli katkılar sağlamaya ve yeni teknikler geliştirmeye devam edecektir (Bhatore vd., 2020).

Uluslararası Finans Enstitüsü ve EY firması (The Institute of International Finance ve Ernst & Young, 2022) tarafından yapılan anket çalışmasına göre makine öğrenmesi uygulamalarının kredi riski ve kara para aklama uygulamalarında önemli bir yeri vardır. Ankete katılan finansal kuruluşların yarısından fazlası kredi riski değerlendirmesinde makine öğrenmesi tekniklerini kullanmakta ve ürünlerinde yeni teknikleri uygulamaktadır (bkz. Şekil

3.1.). Makine öğrenmesi tekniklerini kullandığını belirten firmaların daha çok Euro kullanan ülkelerde olduğu görülürken; Orta Doğu ve Afrika Bölgesi'nin ağırlıklı olarak pilot projeler kullandığı ya da öngörülebilir bir gelecekte kullanacağı ifade edilmiştir.

Şekil 3.1. Kredi Riskine İlişkin Uygulamalarda Makine Öğrenimi Kullanımları

Kredi Riskine İlişkin Analizlerinizde Herhangi bir Makine Öğrenimi uyguluyor musunuz?



Kaynak: The Institute of International Finance ve Ernst & Young (2022)

Örüntü tanımlama ve karar verme yetenekleri ile çeşitli algoritma sınıflandırmalarını kapsayan geniş bir alan (Dixon vd., 2020) olan makine öğrenmesi teknikleri; denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme (Mohammed vd., 2016) öğrenme olmak üzere temel üç sınıfa ayrılmaktadır (bkz. Şekil 3.2).

Şekil 3.2. Makine Öğrenmesi Teknikleri



Kaynak: Financial Stability Board (2017)

i. Denetimli Öğrenme

Bu yöntemlerden denetimli öğrenme, örnek girdi ve çıktı çiftlerine dayalı olarak bir girdiyi bir çıktıyla eşleştiren bir fonksiyonun öğrenildiği makine öğrenimi tekniğidir (Mahesh, 2020).

Veriler, girdinin vektör olarak tanımlanabileceği ve çıktının denetleyici işaret olduğu çiftlerden oluştuğu için etiketli olarak refere edilir (Osisanwo vd., 2017; Nasteski, 2017). Görev odaklı yaklaşımı benimseyen yöntem hedefler belirlendiğinde gerçekleştirilir (Sarker vd., 2020). Algoritmalar, dışarıdan desteğe ihtiyaç duydukları için veri seti eğitim ve test seti olarak ayrılır (Mahhesh, 2020). Etiketlenmiş eğitim verileri ve eğitim örneklerini kullanarak fonksiyonun çıkarımını yapar (Sarker, 2021). Çıkarımları, kullanıldığı sınıflandırma problemlerinde kategorik, genel regresyon problemlerinde sayısal ya da her ikisinin karışımı olan yanıtlar olabilir (Hu vd.,2021). En uygun senaryoda görünmeyen örneklere doğru etiketler ataması için makul bir genelleme yapması beklenir (Somvanshi vd., 2016). Eğitim setinin etiketli ve etiketli olmayan verilerden oluştuğu yarı denetimli çeşitleri de bulunmaktadır (Hu vd., 2021).

Makine öğreniminde sınıflandırma ve kümeleme yöntemleri oldukça yaygın olarak kullanılan teknikleridir. Bu yöntemlerden sınıflandırmanın amacı analiz edilen verileri olası ve istenilen sayıda sınıfları ile eşleştirmektir (Danenas ve Garsva, 2009). Kredi riski dahil finans alanındaki çalışmalarda yaygın olarak kullanılmakta ve bilimsel olarak araştırılmaktadır. Finansal zaman serisi tahmini, volalite tahminleme, hisse senedi piyasalarına yönelik tahminlemeler, temerrüt olasılığı tahmini, iflas tahmini, kredi derecelendirilmesi, finansal riski anlama ve yönetme, döviz kuru, kredi skortlama, banka müşteri profili oluşturma, vadeli alım satım işlemleri ve kara para aklama analizleri kullanım alanlarına örnek olarak gösterilebilir (Härdle vd., 2005; Härdle vd., 2007; Danenas ve Garsva, 2009, Imandoust ve Bolandraftar, 2013).

ii. Denetimsiz Öğrenme

Denetimsiz öğrenme teknikleri, eğitim verilerinin etiketlenmediği ve sınıflandırılmadığı durumlarda kullanılır (Saravanan ve Sujatha, 2018). Verilerdeki kalıpları, benzer temel özelliklere dayanan gözlem kümelerini tanımlayarak tespit etmektedir (FSB, 2017).

Denetimsiz öğrenme yaklaşımları, eğitim süreci gerektirmediğinden denetimli öğrenme yaklaşımlarından farklıdır (Saravanan ve Sujatha, 2018).

Denetimsiz öğrenme, hiyerarşik kümeleme, k-ortalama kümeleme, kendi kendini organize eden haritalar, gauss karışımı ve gizli Markov modelleri gibi küme analizi algoritmalarını içerir (Dixon vd., 2020).

Kalıpların tanımlanması, anormalliklerin tespiti ve verilerin otomatik olarak kategorize edilmesinde faydalıdır (AWS, b.t.). Bu nedenle, genellikle bir veri madenciliği tekniği olarak denetimli algoritmalara tamamlayıcı araç olarak kullanılmaktadır (Bao vd., 2019). Ancak, bu yöntem kesin tahminler sunamamaktadır.

iii. Takviyeli Öğrenme

Takviyeli öğrenme, hedef odaklı öğrenme, karar vermeyi anlama ve otomatikleştirme yaklaşımıdır (Hambly, 2023) ve optimizasyon problemlerini çözer. (Herasymovych vd., 2019). Örnek denetime veya çevrenin modellerine güvenmez ve bireyin çevresiyle doğrudan etkileşiminden öğrenmeye odaklanır (Hambly, 2023). Deneme yanılma yoluyla belirli bir görevin bazı veriler (tahmin, sınıflandırma veya başka bir eylem) üzerindeki performansından elde ettiği olumlu ya da olumsuz geri bildirimleri kendi uyarlar. Yeni görevlerde, aynı yaklaşımı tekrarlayarak ilerler (Sutton ve Barto, 2018).

Çalışmanın model uygulamasında kullanılan, destek vektör makinesi, k-en yakın komşu, rastgele orman, gradyan artırma ve aşırı gradyan artırma denetimli makine öğrenmesi yöntemleri sonraki başlıklarda detaylı olarak incelenmiştir.

3.3.2.1. Makine Öğrenmesi Yöntemleri

Son yıllarda yapay zekâ ve makine öğrenimi teknikleri hızla gelişerek; destek vektör makinesi (Lee, 2007; Mori ve Umezawa, 2007; Bellotti ve Crook, 2009), k-en yakın komşu (Henley ve Hand, 1997; Zhou vd., 2010;), rastgele orman (Barboza vd., 2017; Kulkarni ve Dhage, 2019), gradyan artırma (Turjo vd., 2021) ve aşırı gradyan artırma yöntemlerinin (Wang vd., 2022, Zhang vd., 2023) finans ve kredi değerlendirme alanlarında yaygın olarak kullanılmasına yol açmıştır.

i. Destek Vektör Makineleri

Denetimli makine öğrenmesi tekniklerinden biri olan destek vektör makineleri, birçok uygulama alanında güçlü olan sınıflandırma ve regresyon algoritmalarından biridir (Anguita vd., 2010). Uzaydaki iki sınıf arasındaki mesafelerin toplamını en üst düzeye çıkaran optimal bir ayırıcı hiper düzleme ulaşmak için örneklem noktalarının eşlemesini yapar (Danenas ve Garsva, 2015). Burada yer alan noktalar isminden de gelen destek vektörleri olarak adlandırılırken sınırın orta kısmı ise optimal ayırıcı düzlemdir (Harris, 2015).

Destek vektör makineleri, hiper düzlemde optimal parametreleri elde edebilmek ve sınıflandırma yeteneğini geliştirebilmek için hiper parametre ayarlaması gerektirmektedir (Roy ve Urolagin, 2019). Uygulamalarda birçok veri seti lineer olarak ayrılammamaktadır. Bu nedenle, hiper düzlemde bazı örnekler yanlış ayrılabilir. Bu durumlarda örnekleme daha yüksek boyuta taşımak ve doğrusal bir düzlem elde etmek için farklı Kernel fonksiyonları kullanılabilir (Jun, 2021). Böylelikle, lineer olmayan ve kompleks verilerde modelin doğruluğu artar.

ii. K-En Yakın Komşu Algoritması

K-en yakın komşu algoritması (KNN), sınıflandırma, örüntü tanımlama ve regresyon yöntemlerinde yaygın olarak kullanılan denetimli bir makine öğrenmesi algoritmasıdır (İbrahim ve Abdulazeez, 2021).

Eğitim setindeki diğer veriler analiz edilerek belirlenen uzaklık ölçütüne göre en optimal sınıflandırma yapılır (Uğuz, 2021). Burada, kullanıcı tarafından belirlenen k değeri kullanılmaktadır (Urgiriye ve Bhartiya, 2020). Algoritma, sınıflandırmayı öğrenim setine ve yeni değer için k tane komşusu ile arasındaki yakınlık ölçüsüne göre yapar (Uludağ ve Gürsoy, 2021).

iii. Rastgele Orman

En güçlü makine öğrenimi algoritmalarından biri olan rastgele orman, regresyon ve sınıflandırma çalışmalarında kullanılır. Denetimli makine öğrenme algoritması olan karar ağaçlarını eğiterek bir orman oluşturur ve kararlardaki çoğunluğa göre tahmin yapar (Kaczmarczyk ve Hernes, 2020).

Genellikle kullandığı torbalama tekniğine rastgelelik özelliği eklenerek bu yöntemin geliştirilmiş bir versiyonunu oluşturur (Breiman, 2001). Karar ağaçlarını eğitirken; her bir düğümde rastgele seçilen değişkenler arasındaki seçilen en iyisini rastgele özellik seçimi ile

geliştirerek (Akar ve Güngör, 2012) birleştirir. Veri setindeki sınıf değişkeninin kategorik olması halinde sınıflama, sürekli olması halinde ise regresyon ağaçlarını oluşturur (Akpınar, 2019). Yetiştirdiği birçok sınıflandırma ya da regresyon ağaçlarına ‘Orman’ adı verilir (Pang vd., 2006).

iv. Gradyan Artırma (Gradient Boosting)

Hem sınıflandırma hem de regresyon modellerinde kullanılan gradyan artırma, 2001 yılında Friedman tarafından geliştirilmiş olan bir güçlendirme algoritması diğer bir ifadeyle yükseltme modelidir. Tahmine yönelik modeller oluşturmada kullanılan bir tekniktir. Adını, daha güvenilir ve doğru model oluşturmak amacıyla yüksek önyargılı ve düşük varyanslı zayıf temel öğrenicileri karar ağaçları ile bir araya getiren "yükseltme" fikrinden almaktadır (Bao ve vd., 2019). Dolayısıyla, esasen karar ağacı temelli bir algoritmadır (Kelle ve Yüce, 2022).

Önceki artırma modellerinin kayıp fonksiyonunun gradyan azaltılmasına odaklanmıştır (Chang vd., 2018). Kayıp fonksiyonu hata derecesi olarak yorumlandığı için amaç bu fonksiyonu en aza indirmek diğer bir deyişle gradyan yönünde azaltmaktır (Chang vd., 2018). İlk model tahmini ve sonraki modeller tahminlerin hatalarını verir (Tüfekci ve Önal, 2024). Zayıf tahmin edicilerin hatalarını sonraki aşamalarda düzelterek öncekinin hatalarını düzeltmeye çalışır ve bu aşamaları tekrarlayarak devam eder (Tüfekci ve Önal, 2024). Daha sonra ilk tahmin öğrenilen hatalara göre değiştirilerek tüm bu tahminler toplanır (Čermáková, 2020). Böylelikle, modelin doğruluğu artırılır.

v. XGBoost (Aşırı Gradyan Artırma)

Gradyan artırma algoritmasının optimize edilmiş bir türü olan aşırı gradyan artırma ilk olarak 2016 yılında yayınlanmıştır (Chen ve Guestrin, 2016). Geliştirilmesi veri bilimciler tarafından devam eden yenilikçi bir makine öğrenmesi algoritmasıdır. Kompleks sınıflandırma ve regresyon çalışmalarında kullanılmakta olup doğruluk oranı diğer algoritmalara kıyasla yüksektir (Qin, 2022). Gradyan artırma algoritmasına benzer şekilde modelin tahmin hatasını en aza indirmek için kayıp fonksiyonunu tanımlar ve karmaşıklığını kontrol etmek için de kayıp fonksiyonunun bir varyasyonu olan düzenleme fonksiyonunu tasarlar (Bentéjac ve Martínez, 2021; Liu vd., 2022).

Aşırı gradyan artırma, sağladığı avantajlar ile kullanımı yaygınlaşmıştır. Kaggle’ın makine öğrenmesi alanında 2015 yılında düzenlediği 29 adet yarışmanın yaklaşık %59’unu bu

algoritmayı kullanan çalışmalar kazanmıştır (Chen ve Guestrin, 2016). Mevcutta, ağırlıklı olarak finansal risk kontrolünde kullanılan yöntem, internet finans şirketlerinde kredi risk modellerinin oluşturulması ve analizinde ana yöntem olarak kullanılmaktadır (Li vd., 2021).

Makine öğrenmesi tekniklerinin genel olarak istatistiksel modellerden ve optimizasyon tekniklerinden daha etkili olduğu çalışmalar (Yu vd., 2008; Fantazzini ve Figini, 2009; Bhatore vd., 2020; Busmann vd., 2021) yaygın olmakla birlikte hibrit yöntemler de kullanılmaktadır. Bu çalışmalar istatistiksel modellerin getirdiği kısıtları indirgeme ve tahmin gücü performansının artışına odaklanmışlardır.

3.3.2.2. Makine Öğrenmesi Yöntemlerinin Değerlendirilmesi

Bu yöntemlerden, destek vektör makinelerinin; iyi genelleme yeteneği, optimal çözümü ve ayırt edici gücü bu yöntemin en çok uygulanan yöntemlerden biri olmasını sağlamıştır (Cervantes vd., 2020). Doğrusal ve doğrusal olmayan verilerde çalışabilmekle birlikte aykırı değerlere duyarlı değildir (İbrahim ve Abdulazeez, 2021).

Kullandığı çekirdek fonksiyonların esnekliği ile yüksek boyut sorununu çözmüş olur (Auria ve Moro, 2008). Böylelikle, daha karmaşık problemlerde çalışabilir (Auria ve Moro, 2008). Geleneksel olarak yapısal yanlış sınıflandırma olasılığını en aza indireyecek ayırıcı düzlemi bulur (Jiang vd., 2018). Genelleme yaptığı için aşırı öğrenme sorunu düşüktür. Tüm bu özellikleri ile kredi riski değerlendirmelerinde yaygın olarak kullanılır (Tang vd., 2019).

Destek vektör makineleri, yüksek varyans ve küçük eğitim örneklemelerinde gösterdiği performansın iyi olması nedeniyle, genellikle düşük kalitede ve küçük veri hacimlerine sahip finansal temerrüt verilerinde, kredi riski değerlendirmesi, temerrüt sınıflandırması (Härdle, 2005) ve temerrüt olasılığı tahmini için uygun bir yöntem olarak görülmüştür. Ancak büyük veri setleri ile çalışıldığında, model hesaplama açısından maliyetli ve zaman alıcıdır (Kumar ve Sowmya, 2021). Destek vektör makineleri, şeffaflığın olmaması ve boyutların çok yüksek olması nedeniyle firmaların skorlarını finansal rasyolara ya da farklı bir işlevsel forma dayanan parametrik şekilde sunamaz (Campbell ve Ying, 2022; Duda vd., 2012, akt. Karamizadeh vd., 2014).

Destek vektör makinelerinin ana fikri özel veri noktalarını tanımlamak olduğu için yapay sinir ağları gibi yerel minimum⁵ tuzağına düşmez (Danenas vd., 2011). Bu en güçlü yönlerinden biridir (Danenas vd., 2011). Klasik destek vektör makineleri algoritması, eğitim setinin gürültülü olması ve artıklık durumunda yakınsama hızının yavaş olması ve düşük sınıflandırma doğruluğu nedeniyle bazı dezavantajlara sahiptir (Feng vd., 2009).

K-en yakın komşu algoritması, yalın bir işlem olması, uygulama ve anlamasının kolaylığı sebebiyle makine öğrenmesi algoritmaları arasında yaygın bir kullanıma sahiptir (Kusrini vd., 2019). Kolay yorumlanabilir olması kredi tahmin modelleri için avantajdır (Imandoust ve Bolandraftar, 2013). Ancak, eğitim veri setinin büyük olması halinde verimsiz hale gelir ve çalışma performansı olumsuz etkilenebilir. Genelleme yapmadığı için test aşamasında eğitim veri setlerini tutar başka bir deyişle genelleme yapmak için eğitim verilerini kullanmaz (Song vd., 2017) ve en iyi sonuçlar için hangi uzaklık ya da özelliklerin kullanılacağı belirli olmadığından her sorguda eğitim verilerine olan mesafe yeniden hesaplanır (Imandoust ve Bolandraftar, 2013). Bu çalışma mantığı nedeniyle bellek ve depolama ihtiyacı fazladır ve maliyetli bir yöntemdir.

Tüm veri özellikleri ve sınıflandırması benzerliğe göre çalıştığı için ilişkili olmayan ya da veri fazlalığının olduğu durumlarda, özelliklerin ve ağırlıklarının hatalı seçimi sonuçları olumsuz etkileyebilir. Belirlenen k değerinin olması gerekenden büyük seçilmesi sınıflandırma hatalarına ve beklenenden küçük olması modelin gürültüye duyarlılığını artırır. Bu nedenle, model performansının doğru hesaplanmasının önüne geçer (Eser, 2021).

Rastgele orman algoritması ile ilgili değişkenlerin seçimi kolaydır ve veri setindeki eksik değerlerin etkisine karşı güçlüdür. Bir veri kümesindeki en önemli özellikleri belirlemek için kullanılabilir. Böylelikle, veri işleme ve ön analiz aşamalarında zaman kazandırır. Ancak, ağaç sayısı arttıkça algoritma yavaşlar ve gerçek zamanlı tahminler veremez (Wang vd., 2024). Yüksek boyutta çalışabilir, aşırı öğrenmeyi sınırlar ve yüksek doğruluk sağlar (Kumar ve vd., 2022). Avantaj sağlayan özellikleriyle kredi riskinin makine öğrenmesi uygulamaları içerisinde iyi bir tercihtir (Grennepois vd., 2019).

Gradyan arttırma, işlemi en iyi yapan tahmin edicileri seçerek modele dahil eder (Tüfekci ve Önal, 2024). Böylelikle, hataları azaltma, daha hızlı öğrenme ve iyileştirilmiş tahmin gücü sağlar ve süreci optimize eder (Tüfekci ve Önal, 2024). Gradyan arttırmanın

⁵ Bir noktadaki fonksiyonun değerinin yanında yer alan sol ve sağdaki noktaların fonksiyon değerine eşit ya da küçük olmasıdır (Derspresso, (b.t.).

optimize edilmiş yüksek performanslı hali olan aşırı gradyan artırma, hızlı hesaplama ve daha iyi bir model performansına sahip olup aşırı uyumu önlemektedir (Li, 2019). Yüksek uyum ve güçlü tahminleme yeteneği ile kredi skorlamasında yaygın olarak kullanılmış olup bu skorlama setlerinin büyük ölçekleri ve müşteri özelliklerini sürekli ve derinlemesine analiz etmesi kullanımının uygunluğunu göstermektedir (Z., Li vd., 2021; Balyuk, 2023). Ancak, teknik uzmanlık gerektiren karmaşık bir algoritmadır ve tahminlemeye nasıl gidildiğini anlamak ve yorumlamak zordur. Eğitim verilerine fazla uyum sağlayabileceğinden yeni verilerde hatalı tahminlere yol açabilir.

Sonraki bölümde, çalışma kapsamında incelenen makine öğrenmesi yöntemlerine literatürde yer verilmiştir.

3.3.2.3. Literatür Taraması

Kapsam dahilindeki yöntemlere göre literatürdeki çalışmalar incelendiğinde mali krizlerin ve teknolojinin etkisi gözlemlenmekle birlikte başlangıç uygulamalarından itibaren genel olarak tekniklerin performansının, tahminleme gücünün ve doğruluğun geliştirilmesine odaklanıldığı görülmektedir.

i. Yurt Dışı Çalışmalar

Destek vektör makinesi, k-en yakın komşu, rastgele orman, gradyan artırma ve aşırı gradyan artırma yöntemlerin ele alındığı yurt dışı çalışmalar genel olarak makine öğrenmesi uygulamalarının kredi riski modellerinde geleneksel yöntemlere göre daha iyi performans gösterdiğini belirtmektedir. Veri setinin kalitesinin iyi olduğu ve genel olarak küçük veri setlerinde daha başarılı olan geleneksel yöntemlere kıyasla makine öğrenmesi yöntemlerinin aykırı değerlerin ve eksik verilerin varlığında, büyük veri setlerinde, veri setindeki dengesizliklerinde ve yüksek korelasyonlu değişkenlerin varlığında daha iyi performans gösterdiğinin altı çizilmektedir.

İncelenen çalışmalarda genel olarak piyasa ve kurumların, kredi riski değerlendirmelerindeki riskin azaltılmasının yanında kârlılığın da yükseltilmesi yönündeki beklentilerinin daha belirgin hale geldiği görülmektedir. Rekabetin ve ticaret hacminin arttığı ortamlarda küçük seviyedeki performans veya tahmin farklılıklarının dahi ticari anlamda büyük anlam ifade edebileceğinin altı çizilmiştir. Nitekim, değişen iş ortamında risklerin yönetiminin

önemli olduğu vurgulanmıştır. Bu nedenle, çalışmaların performans, ayrıştırıcı ve tahmin gücünü artırıcı teknikleri veya hibrit yöntemleri uyguladıkları görülmektedir. Dinamik davranış gösteren değişkenlerin modellerin tahmin doğruluğunu arttırdığı ve makine öğrenmesinin geleneksel yöntemlere karşın popülasyondaki değişikliklere dinamik olarak yanıt verme avantajının olduğu belirtilmiştir. Teknolojinin yaygınlaşması ile sosyal medya platformundaki bilgilerin kredi riski değerlendirmelerinde yer almaya başladığı görülmektedir.

Literatürde genel olarak rastgele orman algoritmasının performansı ile öne çıktığı ve aşırı gradyan artırma algoritmasının da iyi sonuçlar verdiği görülmektedir.

Tablo 3.5. Makine Öğrenmesi Yöntemleri Yurt Dışı Literatür Taraması

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Construction of a K-Nearest-Neighbour Credit-Scoring System</i>	W.E. Henley ve D. J.Hand	1997	Postayla Sipariş Başvurusu Bireysel Kredi Riski Başvuru Skorumla, Little Woods Organizasyonu	KNN, Lojistik Regresyon, Projeksiyon Takibi Regresyonu, Karar Ağaçları
SONUÇ/BULGU	K-en yakın komşu algoritması yönteminin kredi riski skorlamasına uygulanmasını inceleyen çalışma, k ve D parametre değerlerinin seçilmesine yönelik bir strateji önermiştir. K-en yakın komşu algoritması, standart regresyon yaklaşımları ve karar ağaçlarından marjinal olarak daha iyi performans göstermiş olsa da aralarında küçük farklılıklar bulunmaktadır. Ancak, bu farklılıklar ticari olarak büyük anlamlar taşıyabilir. Modern bilgisayarların uygulama gücü ile sanayiler içerisinde sınıflandırmanın mümkün olduğu ve k-en yakın komşu yönteminin kredinin reddetme nedenlerini sunarak yasal gereklilikleri karşılayıcı ileri çalışmalar yapıldığı belirtilmiştir. Ayrıca, çalışma göre k-en yakın komşu algoritması geleneksel skorkart yaklaşımlarına göre popülasyonun değişikliklerine dinamik olarak yanıt vererek bunları yansıtmaya avantajı vardır.			
<i>Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications</i>	J. Galindo ve P.Tamayo	2000	Bireysel Kredi Temerrüt ve Kredi Riski, Ticari Banka Ev Kredisi	KNN, CART Karar Ağaçları, Sinir Ağları, Probit
SONUÇ/BULGU	Çalışmaya göre en son teknolojiye sahip model araçları yüksek performansa sahiptir ve binlerce model oluşturarak hata eğrilerine ait davranışların incelenmesine olanak tanır. Çalışmada, karar ağaçlarının 120 düğüm ile en iyi model olduğu bulunmuştur. CART yönteminin %8.3 ile en iyi modeller arasındaki en düşük hata oranına, 0,073 gürültü/bias, 21,7 kompleksite ve 21.675 optimum eğitim örneklem büyüklüğünde ulaştığı görülmektedir. Modeller arasında kompleksitesi en yüksektir. 2.000 kayıt ile %11 ortalama hata oranına sahip ikinci sırada yer alan model 120 gizli katmanlı sinir ağlarıdır. Probit ise %15,13 hata oranını, 0,15 gürültü, 1,80 kompleksite ve 1,804 optimum eğitim örneklem büyüklüğüne sahiptir. Modeller arasında en yüksek hataya ve en düşük kompleksiteye sahiptir. Probitten sonra en yüksek hata oranı k-en yakın komşu algoritmasına ait olup bunun sebebinin modelin veri setinin küçük oluşu olarak gösterilmiştir. Çalışma sonucunda ilgili ölçüm metriklerinin modelleri anlamada faydası olsa da ilerleyen çalışmalar için karşılaştırmalı analiz yapılması önerilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Benchmarking State-Of-The-Art Classification Algorithms for Credit Scoring</i>	B. Baesens, T. Van Gestel, S. Viaene, M. Stepanova, J. Suykens ve J. Vanthienen	2003	Kredi Skolama Benelux (Belçika, Hollanda ve Lüksemburg) ve İngiltere Verileri için 2 Finansal Kuruluş Kredi Verisi, UCI Deposu Alman ve Avustralya Kredi Verisi	Lojistik Regresyon, Doğrusal Ayırma Analizi, Kuadratik Ayırma Analizi, Doğrusal Programlama, Sinir Ağları, Naif Bayes, Karar Ağaçları ve kuralları (C4.5 algoritması), KNN10, KNN100, DVM (RBF LS-DVM, Lin LS-DVM, RBF DVM, Lin DVM), TAN (Ağaç Arttırılmış Naif Bayes)
SONUÇ/BULGU	Birçok sınıflandırma tekniğinin performansını farklı veri setlerinde karşılaştıran bu çalışma doğrusal olmayan RBF LS-Destek vektör makinelerinin iki kez ilk sırada yer aldığı ve sinir ağlarının dört kez ilk sırada yer aldığı ROC eğrisi altındaki alana göre mükemmel performans gösterdiğini bulmuştur. Benzer şekilde doğru sınıflandırma yüzdesine göre de bu iki yöntem en iyi performansı göstermiştir. Sinir ağları ise diğer yöntemler ile kıyaslandığında tüm veri setlerindeki AUC değerlerine göre dört kez en iyi performansa sahip olmuştur. Lojistik regresyon ve doğrusal ayırma analizleri de kredi skorlamasında iyi performans göstermiştir. Gelecekteki çalışmalar için bağımlı değişkenin sürekli olduğu ya da çoklu sınıflandırma algoritmalarının birleştirilerek oylama yöntemine göre sınıflandırma yapılması konularının ele alınmasının umut verici yöntemler olabileceği belirtilmiştir.			
<i>An Application of Support Vector Machines in Bankruptcy Prediction Model</i>	Kyung-Shik Shin, Taik Soo Lee ve Hyun-Jung Kim	2005	Kurumsal İflas Tahmini, Orta Ölçekli İmalat Firmaları, Kore Kredi Garanti Fonu Verileri	Destek Vektör Makineleri Geriye Yayılımlı Sinir Ağları
SONUÇ/BULGU	Çalışmada, destek vektör makineleri yaklaşımının etkinliğinin değerlendirilmesi için kurumsal iflaslardaki sınıflandırma parametrelerinde çeşitli Kernel parametreleri ve üst sınır C'si dikkate alınarak çeşitli parametrelerle test seti boyutu küçültülerek denenmiştir. Eğitim seti boyutu küçüldükçe destek vektör makinelerinin daha iyi performans gösterdiği bulunmuştur. Ayrıca, 5., 6 ve 7. veri setlerinde, veri boyutunun daha büyük olduğu 3 ve 4. sete göre genelleme ve doğruluk performansı daha yüksektir. Geri yayılımlı sinir ağlarının küçük veri setlerinde modeli öğrenmesi zor olduğundan ağ ağırlıklarını türetmeden optimum çözümü çıkaran destek vektör makinelerine göre sınırlaması vardır. Parametre seçiminde destek vektör makinelerinin kernel ve üst sınır C olmak üzere iki tane olması ve geriye yayılımlı sinir ağlarının çoklu parametrelili olması nedeniyle destek vektör makineleri daha basit bir yöntemdir. Ayrıca, çalışmada destek vektör makinelerinin performansının bağlı olduğu parametrelerin optimal değerinin seçilmesi için yöntem geliştirilmesini ve genelleme performansını ölçmek için bir kılavuz sağlanmasını gelecekteki araştırmalar için önemli olduğunun altı çizilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Credit Risk Evaluation with Least Square Support Vector Machine</i>	Kin Keung Lai, Lean Yu, Ligang Zhou ve Shouyang Wang	2006	Bireysel Kredi Riski Tahmini, İngiltere Finansal Servisler Şirketi Verileri	Doğrusal Regresyon, Lojistik Regresyon, Yapay Sinir Ağları, DVM, FDVM, LS-FDVM
SONUÇ/BULGU	Çalışma ile en küçük kareler bulanık destek vektör makineleri modeli önerilmiş olup iyi müşterileri kötü müşterilerden ayırıcı bir araştırma yapılmıştır. Bu model, kredi riskinin daha ayrıntılı değerlendirilebilmesini her eğitim noktasıyla ilişkili bulanık üyeliğini dikkate alarak sağlamaktadır. LS-FDVM, %81,46 Tip I doğruluk, %92,79 Tip II ve %88,58 doğruluk ile yaygın olarak kullanılan diğer sınıflandırıcılardan daha yüksek performans göstermiştir. Bu nedenle, çalışma LS-FDVM'nin kredi risk değerlendirmeleri için uygun alternatif bir çözüm olarak önermiştir. Çalışmada genel doğruluk değeri için en düşük değer %50,22 ile doğrusal regresyon olduğu sonucuna varılmıştır.			
<i>Application of Support Vector Machines to Corporate Credit Rating Prediction</i>	Young-Chan Lee	2007	Kurumsal Kredi Derecelendirme/Notu Tahmini Kore Bilgi Hizmetleri A.Ş. Verileri	Vaka Tabanlı Öğrenme, Destek Vektör Makineleri, Geri Yayılımlı Sinir Ağı, Çoklu Doğrusal Ayırma Analizi
SONUÇ/BULGU	Çalışmada, destek vektör makinelerinin RBF çekirdek fonksiyonunun optimal parametre değerleri, ızgara araması kullanan 5 katlı çapraz doğrulama tekniği ile bulunmuştur. Ancak, bu teknik bu probleme özgüdür. Test setindeki genel sınıflandırma doğruluk oranı %67,22 ile en yüksek destek vektör makineleri olmuştur. Çoklu doğrusal ayırma analizi %58,72 oranı ile en düşük doğruluğa sahiptir. Ayrıca, destek vektör makinelerinin avantajlarını da değerlendiren çalışma, doğrusal olmayan veri ile çalışabildiği ve aşırı uyumu önlediği belirtilmektedir. Çalışmada özellikle, makine öğrenmesi tekniklerinin başta destek vektör makineleri olmak üzere kurumsal kredi derecelendirme tahminlerinde ilerlediği ifade edilmiştir. Çalışmada ayrıca sınıflandırma problemlerinin türüne özgü olarak uygun çekirdek fonksiyonlarını ve parametre değerlerinin seçilmesi gerektiği ifade edilmiştir.			
<i>Credit Risk Evaluation in Power Market with Random Forest</i>	Hiroyuki Mori ve Yasushi Umezawa	2007	Kurumsal Kredi Riski Değerlendirmesi, Japonya Elektrik Enerji Borsası Kuruluşları	Rastgele Orman, CART (Sınıflandırma ve Regresyon Ağaçları) ve MLP (Çok Katmanlı Algılayıcılar)
SONUÇ/BULGU	Çalışma, elektrik şebekesinin serbestleştirilmesi ile rekabetin ve düzensizliğin arttığı enerji piyasası için kredi riski değerlendirmesinde rastgele ormanı kullanan yeni bir metot önermiştir. Beklenmedik kâr kayıplarından tedirgin olan piyasanın beklentisi karı yükseltmek ve riski azaltmaktır. Diğer yöntemler ile karşılaştırıldığında, rastgele orman tanınma oranı diğer bir ifadeyle test verilerinden elde edilen doğru çözümlerinin sonucu CART için %10,53 ve MLP için %5,26 olmak üzere daha yüksektir. Çalışma sonucuna göre en önemli dört değişken sırasıyla, satış, net gelir, olağan gelir ve uzun vadeli borçlardır.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Support Vector Machines for Credit Scoring and Discovery of Significant Features</i>	Tony Bellotti ve Jonathan Crook	2009	Finansal Kuruluş Kredi Kartı Temerrüt Riski	DVM, Lojistik Regresyon, Doğrusal Ayırma Analizi ve KNN
SONUÇ/BULGU	Çalışma sonucunda, destek vektör makinelerinin geleneksel yöntemlere kıyasla temerrüt riskinde daha başarılı olduğu ve özellik seçiminde kullanılabileceği bulunmuştur. K-en yakın komşu algoritması ve polinom kernelli destek vektör makineleri en düşük performansa sahiptirler. Polinom kernelli destek vektör makinelerinin aşırı uyum problemi vardır. K-en yakın komşu algoritmasının düşük performansı Basenes (2003) çalışması ile benzerdir. Önceki çalışmalara göre daha büyük bir veri setinde başarılı sonuçlar elde edilmiştir. Ayrıca, diğer birçok öğrenme görevinin aksine, kredi verilerinin doğası gereği en iyi performansı elde etmek için büyük bir destek vektör sayısına ihtiyaç duyulduğu bulunmuştur. Ürün tipinin (kredi kartı türü) temerrüt riski için önemli olduğu tespit edilmiştir. İlerleyen çalışmalar için her bir ürüne ayrı modelleme kullanılarak performansların değerlendirileceği belirtilmiştir.			
<i>Least Squares Support Vector Machines Ensemble Models for Credit Scoring</i>	Ligang Zhou, Kin Keung Lai ve Lean Yu	2010	Bireysel Kredi Skorumla İngiltere Finansal Servisler Şirketi Verileri UCI Deposu Alman Kredi Verisi	En Küçük Kareler Destek Vektör Makineleri ve 19 Adet Diğer Sınıflandırma Modeli
SONUÇ/BULGU	Çalışmada, kredi riski değerlendirmesi için destek vektör makineleri topluluk öğrenmesine ait teknikler önerilmiştir. Ancak, bu yöntemler tüm veri setlerinde en iyi sonucu vermemiştir. İngiltere finansal servisler veri 2 setinde, KNN50 doğru sınıflandırma yüzdesi (PCC, percentage correct classification) ölçümünde en iyi sonuçları vermiştir. Güven seviyesi %5 olduğunda destek vektör makineleri tabanlı topluluk modellerinin tamamının istatistiksel olarak KNN50 sınıflandırıcısı ile aynı performansı verdiği belirtilmiştir. Yapılan deneylerin sonucu olarak topluluk yöntemlerinin iyi ve dayanıklı (robust) olduğu ve iyi çözümler vadetmesine rağmen eleman sınıflandırıcılarının yüksek doğrusal korelasyona sahip olduğu belirtilmiştir. Çalışmaya göre ayırt etme yeteneğindeki en küçük artış ilerde önemli tasarruflara dönüşebilir.			
<i>An Experimental Comparison of Classification Algorithms for Imbalanced Credit Scoring Data Sets</i>	Iain Brown ve Christophe Mues	2012	Kredi Skorumla Temerrüt Riski Benelux (Belçika, Hollanda ve Lüksemburg) ve İngiltere Verileri İçin 2 Finansal Kuruluş Kredi Verisi UCI Deposu Alman ve Avustralya Kredi Verisi	Lojistik regresyon, Doğrusal Ayırma Analizi (LDA), Kuadratik Ayırma Analizi (QDA), Sinir Ağları, En Küçük Kareler DVM (LS-DVM), C4.5. karar ağaçları, KNN10, KNN100, Rastgele Orman, Gradyan Artırma
SONUÇ/BULGU	Çalışmada, kredi puanlama bağlamında henüz tam anlamıyla araştırılmayan rastgele orman ve gradyan artırma yöntemleri incelenmiş ve AUC performans ölçütlerine göre aşırı sınıf dengesizliklerinde çok iyi performans sağladıkları bulunmuştur. Doğrusal ayırma analizi ve lojistik regresyon, veri seti dengesiz olmasına rağmen daha karmaşık olan metotlar ile makul ölçüde rekabetçi performans göstermiştir. Burada, kredi verilerinin genellikle dengesiz dağılıma sahip olduğu da belirtilmiştir. Gelecek çalışmalar için bu tekniklerin daha geniş bir sınıf dağılımı gösterir büyük veri setlerine uygulanması ve ayrıca sınıf dağılım yüzdesinin yanında veri setindeki gerçek gözlem sayısının etkisine de bakmanın ilginç olacağı belirtilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Business Analytics Using Random Forest Trees for Credit Risk Prediction: A Comparison Study</i>	Nazeeh Ghatasheh	2014	Kredi Riski Tahminleme, UCI Deposu Alman Kredi Verisi	Rastgele Orman Ağaçları, AdaBoost, Doğrusal Kernel Kullanan DVM
SONUÇ/BULGU	Mevcut literatürde önerilen yapay sinir ağları, destek vektör makineleri ve bulanık öğrenme gibi yöntemler önerilse de bu yaklaşımların bazıları kara kutu modelleri olarak kabul edilirler. Bu nedenle her bir faktörün tahmin üzerindeki etkisinin daha fazla değerlendirmesi ve açıklaması olan modellerden rastgele orman bazı araştırmacılar tarafından önerilmektedir. Çalışmada, rastgele orman ağaçları, 100 ağaç ve 16 değişken ile %80 AUC performansı ve birçok metrikte iyi performans göstermiştir. Çalışmaya göre, değişen iş alanlarındaki risklerin etkin yönetimi için karar vermede etkili bir yardımın olması gerekmektedir. Çalışma, rastgele orman algoritmasını kredi riskinde umut vadettiğini belirtilmiştir. Algoritmanın sadeliği ve sınıflandırma yeteneklerini, tahminlemede kullanmanın bir fırsat olduğu belirtilmiştir. Gelecekteki çalışmalar için karar ağaçlarının büyütmenin yolunu arttırarak daha iyi değişken seçiminin sağlanması ve sınıflandırma modellerinin kapısını açtığı belirtilmiştir. Ayrıca, rastgele ormanın hibrit yaklaşımları için daha kapsamlı araştırmalar yapılması gerekmektedir.			
<i>Machine Learning Models and Bankruptcy Prediction</i>	Flavio Barboza, Herbert Kimura ve Edward Altman	2017	Kurumsal İflas Tahmini, Amerika ve Kanada Firmaları Compustat Verisi, NYU Salomon Merkezi Veri Tabanı İflas Verileri	Doğrusal DVM, RBF DVM, Artırma (Boosting), Torbalama (Bagging), Rastgele Orman, Sinir Ağları, Logit, Çoklu Ayrırma Analizi
SONUÇ/BULGU	Çalışmaya göre, makine öğrenimi modelleri, geleneksel modellere kıyasla %10 daha fazla doğruluk göstermiştir. Makine öğrenmesi modelleri %71 ve %87 aralığında tahmin kapasitesine sahipken çoklu ayırma analizi, lojistik regresyon ve yapay sinir ağları geleneksel yöntemlerinin tahmin değerleri %52 ile %77 arasındadır. Test seti için tüm değişkenlerin dahil edildiği (Z skor değişkenleri dahil) modelde, rastgele ormanın doğruluk seviyesi %87 iken geleneksel modellerden en iyileri olan lojistik regresyon %69 ve doğrusal ayırma analizi %50 seviyesinde kalmıştır. En iyi modeller olan torbalama, artırma ve rastgele ormanın yeni değişkenler eklendiğinde tahmin doğrulukları artmıştır. Ancak, çalışmaya göre makine öğrenmesi modelleri mükemmel değildir. Örneğin, doğrusal destek vektör makineleri, doğrusal ayıramayan veri kümelerinde daha çok hatalı sınıflandırmaya sebep olmakta ve zorlanmaktadır. DVM-RBF, hata oranlarını azalttı ancak diğer makine öğrenimi modellerine göre daha zayıf performansa sahipti. Ayrıca, destek vektör makinelerinin hesaplama süresi diğerlerine göre daha uzundu. Çalışmada, yüksek korelasyonlu değişkenlerin, aykırı değerlerin ve eksik değerlerin varlığı gibi kısıtlayıcı koşullar altında makine öğrenimi modellerinin kullanılmasıyla önemli tahmin doğruluğunun elde edilmiştir. Değişkenlerde herhangi bir değişim ve dönüşüm yapılmadığı için makine öğrenmesi modellerinin daha iyi sonuç ürettiği belirtilmiştir. Bu nedenle, geleneksel yöntemlere kıyasla daha kolay uygulanabileceklerini ve daha iyi performans gösterdiklerine değinilmiştir. Firma başarısızlıklarının iflastan bir yıl öncesinde değil ancak zaman içerisindeki zorluklardan dolayı da ortaya çıkabileceğinden, burada makine öğrenmesi tek bir değişkenin kısa vadeli gelişimi hakkında bilgileri modele kolayca dahil ettiğinden dolayı avantajlıdır. Böylelikle, zaman serileri ya da hayatta kalma analizlerinin kullanıma gerek kalmamıştır. Bu nedenle, firmaları basit ancak dinamik davranış gösteren değişkenlerinin eklenmesi makine öğrenmesi modelleri tahmin doğruluklarındaki başarılarını arttırabilir. Çalışmada, kredi risk çalışmalarında makroekonomik değişkenlere ilişkin modellerin daha fazla araştırılması önerilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Advanced Credit Score Calculation Using Social Media and Machine Learning</i>	Swati V. Kulkarni ve Sudhir N. Dhage	2019	Banka Bireysel Kredi Puanı UCI Deposu Kredi Verisi	Naif Bayes, Rassal Ağaç, Rastgele Orman, MLP (Çok katmanlı Algılayıcı)
SONUÇ/BULGU	Çalışmada, bireyin mali geçmişine dayanan kredi puanı ile sosyal medya ve diğer web etkileşimlerinin analiziyle elde edilen duygusal/sosyal kredi puanı üzerinden gelişmiş kredi puanı oluşturulmuştur. Bu da kişilik özelliklerinin dahil edildiği daha hassas bir sonuç doğurmuştur. Bilgi güvenilirliği hesaplaması adıyla geliştirdikleri teknik bireylerin sosyal medya hesaplarından elde edilen veriler ile banka verilerini karşılaştırmaktadır. Klasik kredi puanı ve duygusal/sosyal kredi puanı üzerinden gelişmiş kredi puanı hesaplanmaktadır. Puanın doğruluğu, bu iki puanlamanın kesirlerine bağlıdır. Uygulanan yöntemlerden %84,64 ile naif bayes ve sonrasında %84,47 ile rastgele orman en yüksek doğruluk değerlerine sahiptir. Çalışmaya göre uygulamanın mevcut sistemden daha etkili olacağı düşünülmektedir. Daha önce kredi ya da kredi kartı kullanmamış ya da birçok kez temerrüde düştüğü için klasik kredi puanı ile başvurusu değerlendirilemeyecek olan bireylerin kredi risk analizinde kullanılabileceği belirtilmiştir.			
<i>Corporate Default Forecasting with Machine Learning</i>	Mirko Moscatelli, Fabio Parlapiano, Simone Narizzano ve Gianluca Viggiano	2020	Kurumsal Temerrüt Riski Tahmini, İtalyan Finansal Olmayan Şirketleri	Doğrusal Ayırma Analizi, Lojistik Regresyon, Cezalandırılmış Lojistik Regresyon (PLR), Rastgele Orman, Gradyan Artırma Ağaçları (GBT)
SONUÇ/BULGU	Çalışmada, nadir olaylar seti olduğu için yaygın kullanılan alt örnekleme metodu denenmiş ancak gerçek ekonomi verisiyle uyumlu olmadığı için Bayes düzeltmesi yapılarak iflas olasılığı gerçek seviyelere uyumlu hale getirilmiştir. Çünkü, veri setlerinde genellikle temerrüde düşenler, düşmeyenlere göre oldukça küçük bir paya sahiptir. Bu durum ayrıştırıcı tahminleme gücünü de zayıflatır. Uygulanan modellerin temerrüt tahminlerinin ayrıştırma gücü AuROC (Alıcı İşletim Karakteristik Eğrisi Altında Kalan Alan) karşılaştırılarak yapılmıştır ve ağaç temelli modellerin istatistiksel modellere göre daha iyi performans gösterdiği bulunmuştur. Kredi davranışlarına ait değişkenler modele dahil edildiğindeyse hesaplar için AuROC'ta ayrıştırıcı tahmin gücü yaklaşık %10 civarında artış göstermiştir. Ancak, tahminleme gücünün artışında makine öğrenmesi modellerininki ve lojistik regresyona göre daha az belirgindir. Yüksek kaliteli verilerle lojistik regresyonun tahminleme gücü zaten yüksektir. Başka bir ifadeyle, sınırlı bir bilgi seti mevcut olduğunda örneğin kredi riskinin harici bir değerlendirmesi durumunda, makine öğrenimi modellerinin istatistiksel modellere göre ayırma gücü ve kesinlik açısından kazanımları daha fazladır. Ancak, veri setine gizli bilgilerin de girdiği ve veri setinin küçük olduğu durumlarda bu avantaj azalır. Çünkü, makine öğrenmesi modellerinin yüksek tahmin gücüne sahip olması için gözlem sayısının fazla olmasını gerektiğini bulmuşlardır. Makine öğrenimi modelleri, daha büyük miktarda krediyi daha güvenli ve daha büyük borçlulara yoğunlaştırmış ve böylelikle kredi verenlerin kredi kayıplarının azalmasına neden olması beklenir. Bu nedenle, çalışma istatistiksel ve makine öğrenmesi metotlarının kombine yöntemini kredi analistleri için önermiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Comparative Analysis and Implementation of Credit Risk Prediction Through Distinct Machine Learning Models</i>	Aquib Abtahi Turjo, S.M. Mynul Karim, Tausif Hossain Biswas, Yeaminur Rahman ve Ifroim Dewan	2021	Banka Kredi Başvuru Skorlama, Kaggle Verisi	KNN, Lojistik Regresyon, Doğrusal Regresyonu, Rastgele Orman, AdaBoost, ANN, Gradyan Artırma
SONUÇ/BULGU	Çalışmada, en yüksek doğruluk olan %84,6 seviyesine gradyan artırma modeli ile ulaşılmıştır. Doğruluk oranında çalışmada referans gösterilen önceki çalışmalara kıyasla daha yüksek başarı sağlanmıştır. Diğer çalışmalara kıyasla algoritmaların performansları birbirlerine yakın seyretilmiştir.			
<i>Research on Personal Credit Risk Evaluation Based on XGBoost</i>	Kui Wang, Meixuan Li, Jingyi Cheng, Xiaomeng Zhou ve Gang Li	2022	Banka Bireysel Kredi Temerrüt Riski	XGBoost, Karar Ağaçları, KNN
SONUÇ/BULGU	Çalışmaya göre kişisel kredi risk değerlendirmelerindeki özniteliklerin temerrüt durumu ile ilişkisi azdır. Bu nedenle, çalışmada öznitelik seçimlerinde lojistik regresyon yöntemleri ile bir endeks sistemi oluşturulmuştur. Oluşturulan bireysel kredi modeli, sınıflandırma metotlarından olan aşırı gradyan artırma, karar ağacı ve K- en yakın komşu algoritmalarının endeks performansları AUC, doğruluk ve Tip II hata değerleri üzerinden değerlendirilmiştir. Bireylerin, yaş, evlilik durumu, teminat tipi, kredi vadesi, eğitim seviyesi gibi 26 değişken kullanılmıştır. AUC ve doğruluk değerlerine göre en iyi performansı aşırı gradyan artırma yaklaşımı göstermiştir. İkinci sırada karar ağaçları yer almaktadır. K-en yakın komşu algoritması en düşük performansa sahiptir. Tip II hata oranını en iyi olan karar ağaçlarıdır ve aşırı gradyan artırma ile yakın değere sahiptir. Çalışma sonucunda, aşırı gradyan artırma metodunun temerrüt oranlarını iyi ayırttığı ve dayanıklılığının iyi olduğu görülmüştür.			
<i>An Explainable Financial Risk Early Warning Model Based On The Ds-XGBoost Model</i>	Tianjiao Zhang, Weidong Zhu, Yong Wu, Zihao Wu, Chao Hang ve Xue Hu	2023	Finansal Risk- İflas Riski, Çin Üretim Firmaları	XGBoost, DS-XGBoost, Rastgele Orman, Lojistik Regresyon
SONUÇ/BULGU	Finansal veriler, kurumsal yönetim ve yönetimin yaklaşımı sergileyen veriler ile 341 Çinli üretim firmasının 2012 ve 2021 yılları arasındaki toplam 25 değişken kullanarak finansal erken uyarı sistemi için model oluşturmuşlardır. Kurumların mali verilerinden oluşturulan operasyonel yetkinlik, kârlılık, gelişim, nakit akış verilerinin yanında kurumsal yönetim için yönetim kurulu üye sayısı, bağımsız direktörler ve rasyosu, mülkiyet durumu ve yönetim yaklaşımı için firmaların yıllık raporlarında yer alan yönetimin düşüncelerine ve beklentilerine yer veren MD&A (management discussion and analysis) kısmını kullanmışlardır. Model performans karşılaştırmalarında aşırı gradyan artırma uygulamalarının, karar ağaçları ve lojistik regresyona göre daha iyi performans gösterdiği bulunmuştur. Model, yatırımcılara ek karar desteği sağlamak ile kural koyucu otoritelerin sermaye piyasasındaki finansal riskler için ön uyarı sağlayacağından daha kararlı ve sağlıklı büyüme sağlanmasına yardımcı olabilir.			

Kaynak: Yazar tarafından oluşturulmuştur.

iv. Yurt İçi Çalışmalar

Destek vektör makinesi, k-en yakın komşu, rastgele orman, gradyan artırma ve aşırı gradyan artırma yöntemlerin ele alındığı yurt içi çalışmalar genel olarak finansal verilerin yanında davranışsal verilerin kredi riski tahmininde etkili olduğunu belirtmiştir. Çalışmalarda kullanılan veri setine göre en başarılı yöntemlerin değiştiği görülse de gradyan artırma ön plana çıkmaktadır. Çalışmalarda, satış, protestolu çek/senet, kredi türü ve bölge değişkenleri anlamlı bulunmuştur.

Tablo 3.6. Makine Öğrenmesi Yöntemleri Yurt İçi Literatür Taraması

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Estimation of Credit Card Customers Payment Status by Using KNN and MLP</i>	Murat Koklu ve Kadir Sabancı	2016	Kredi Kartı Temerrüt Riski, UCI Machine Learning Repository Veri Deposu	K- En Yakın Komşu ve MLP (Çok Katmanlı Algılayıcı)
SONUÇ/BULGU	Çalışmanın sonuçlarına göre, k-en yakın komşu algoritmasında katman sayısı arttıkça başarı oranı artmış ve 10'lu komşu değeri için en yüksek performansı olan %80,6569'e ulaşmıştır. Ortalama mutlak hata değeri (MAE) 0.2743 ve hataların karesinin ortalamasının karekökü (RMSE) 0,3897'dir. Çalışma sonucunda, çok katmanlı algılayıcının (MLP) tek katmandaki %81,049 başarı değerinin k-en yakın komşu algoritmasına göre daha yüksek olduğu görülmüştür. Bu değerın MAE'si 0.3237 ve RMSE'si 0,388'dir.			
<i>Makine Öğrenmesi Yöntemleri ile Kredi Riski Analizi</i>	Sacide Kalaycı	2018	Banka Kurumsal Kredi Başvuru Skorlama Analizi, KOBİ	Lojistik Regresyon, Karar Ağaçları, Destek Vektör Makineleri, Sinir Ağları, Rastgele Orman Algoritması ve Gradyan Artırma
SONUÇ/BULGU	Çalışmanın model sonucunda k 5 katlı çapraz doğrulamaya göre gradyan artırma %84,2+/-0,9 ve rastgele orman algoritmaları %83,08+/-1,5 en başarılı iki model olarak belirlenmiştir. Müşterinin ödeme davranışlarının incelenmesinin modelin başarısını arttırdığı ve standart sapmasını düşürdüğü belirtilmiştir. Algoritmanın sistem başarısına etki eden en önemli 15 özneliğin %67'si geri ödeme performansından geri kalanı ise müşterilerin diğer bilgilerinden oluşmaktadır. Bu özneliklerle elde edilen başarı oranı test seti için %79,82'dir. Ayrıca, 4 farklı algoritma ile harmanlanmış yöntemlerle oluşturulan yöntemlerin, gradyan artırma modelinin başarısı kıyaslanmış ve tamamı tek başına kullanılan bu algoritmadan daha iyi performans göstermiştir. Bu nedenle çalışma harmanlanmış sistemlerin kullanımını önermiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Kredi Risk Analizlerinde Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağlarının Karşılaştırılması</i>	Mehmet Yazıcı	2018	Banka Kurumsal Kredi Riski, KOBİ	Doğrusal Ayırma Analizi, Lojistik Regresyon ve Yapay Sinir Ağları
SONUÇ/BULGU	Çalışmada, doğrusal ayırma analizinde, nakit oran, maddi duran varlıklar/özkaynak, protestolu çek/senet kaydı, satışların mevsimselliği, profesyonel finans yönetiminin varlığı ve TL mevduat değişkenleri anlamlı bulunmuştur. Deney grubu %85 seviyesinde doğru sınıflandırma yaparken, test grubunun doğru sınıflandırma yüzdesi %34 seviyesinde çıktığı için modelin güvenilirliğini etkilemiştir. Lojistik regresyon modelinde ise anlamlı bir sonuca ulaşamamıştır. Ancak, protestolu çek/senet kaydının sınıflara ayırmada en etkili değişken olduğu belirtilmiştir. Çalışma sonucunda, yapay sinir ağlarının test grubunda %96 seviyesinde doğru sınıflandırma yapılmıştır.			
<i>Makine Öğrenmesi Teknikleriyle Kredi Başvuru Skor Kartının Oluşturulması</i>	Nesrin Akpınar	2019	Finansal Kuruluş Başvuru Skorumla Bireysel Ürün (Kullanılan KKB Verilerinden Bireysel Bir Ürün Olduğu Tahmin Edilmektedir.)	Lojistik Regresyon, Karar Ağaçları, Rastgele Orman ve Gradyan Artırma
SONUÇ/BULGU	Çalışmaya göre popülasyonun alt segmentlerden oluşması halinde tecrübe ve sektör bilgisine göre ya da kümeleme ve karar ağaçları gibi yöntemler kullanılarak ayrıştırılması gerekmektedir. KKB verilerinin kullanımının geçmiş verileri içermesi sebebiyle trendleri yakalamada faydalı olmaktadır. Lojistik regresyon ve gradyan artırma modelleri hassaslık, duyarlılık ve F1 skorları çok benzer olduğu için AUC ve gini istatistiği yüksek olan gradyan artırma modeli tercih edilmiştir. Ancak, çalışma sonucunda %78,07 AUCROC değeri olan gradyan artırmaya %77,73 oranı ile lojistik regresyonun yakın seyrettiğini de belirtmek gerekir.			
<i>Kurumsal Kredi Skorumasında Klasik Yöntemlerle Yapay Sinir Ağı Karşılaştırması</i>	Şahap Kavcıoğlu	2019	Banka Kurumsal Kredi Skorumla, KOBİ Temerrüt Riski	Lojistik Regresyon, Yapay Sinir Ağları
SONUÇ/BULGU	Çalışmanın lojistik regresyon sonucunda, davranışsal değişkenlerin yer aldığı modülün etkisinin finansal modüle oranla daha yüksek olduğu görülmüştür. Modelin gini değeri lojistik regresyon için %57,9 iken yapay sinir ağlarında %76,2 olmuştur. Ancak, çalışma sonucunda örneklem dışı verilerde modellerin performansının ciddi oranda olumsuz etkilendiği ve lojistik regresyonun daha iyi performans gösterdiği görülmüştür.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Makine Öğrenmesi Yöntemleriyle Kredi Riski Tahmini</i>	Hamdi Okur	2020	P2P Kredi Riskine Etki Eden Sebepler, Lending Club Kredi Verileri	Regresyon: Doğrusal Regresyon, Karar Ormanı Regresyonu, Yapay Sinir Ağları Regresyonu, Artırılmış Karar Ağacı Regresyonu. Sınıflandırma: Derin Destek Vektör Makinesi, Karar Ormanı, Arttırılmış Karar Ağacı, Yapay Sinir Ağları
SONUÇ/BULGU	Çalışmada, regresyon ve sınıflandırma yöntemlerinin başarıları kendi içlerinde değerlendirilmiştir. Regresyon yöntemlerinde başarı ölçütlerine göre doğrusal regresyon en başarısız yöntem olarak çıkarken; artırılmış karar ağacı regresyonu en başarılı yöntem olarak çıkmıştır. Sınıflandırma yöntemlerinde ise en başarılı sonuca ikili sınıflandırılmış karar ağacı ulaşmıştır. Kullanılan veri seti ile yapılan başka bir çalışmada lojistik regresyon, naif bayes ağları ve destek vektör makinaları ile risk tahmini yapılmıştır. Önceki çalışmadan daha başarılı sonuçlar elde edilmesine, kullanılan parametre ve normalizasyonun neden olduğu kanaatine varılmıştır. Çalışmaya göre, gelir dağılımı, müşterinin bulunduğu bölge, kredi türü ve faiz oranı kredi riskini belirleyen faktörlerdir.			
<i>Credit Risk Analysis Using Machine-Learning Algorithm</i>	Gökhan Alagöz ve Ethem Çanakoğlu	2021	Finansal Kuruluş Kredi Temerrüt Riski Skorlama	Lojistik Regresyon, Yapay Sinir Ağları ve Rastgele Orman
SONUÇ/BULGU	Lojistik regresyon, yapay sinir ağları ve rasgele orman modellerinin başarıları ROC eğrisine göre kıyaslanmış ve lojistik regresyonun diğerlerine kıyasla daha kullanışlı ve daha başarılı olduğu belirlenmiştir. AUC değerleri sırasıyla, %94,9, %91,8 ve %92,3'tür. Hata matrisine göre modellerin tümü gerçek ile tutarlı sonuçlar üretmiştir. Sınıflandırma sonuçlarının değerlendirildiği %86 kesinlik, %83 duyarlılık ve %84 F1 skor değerlerinde lojistik regresyon en başarılı yöntemdir. En yakın başarı yüzdesi rastgele orman yönteminin %81 kesinlik skoru haricinde diğer sonuçlar arasında ciddi fark bulunmaktadır. Ancak, yöntemlerin doğruluk değerleri birbirlerine oldukça yakındır. Lojistik regresyonun ürettiği sonuçlar ile temerrüt riski kullanımında etkili olduğu belirtilmiştir.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Türk Bankacılık Sisteminde UFRS Çerçevesinde Firmaların Derecelendirilmesi ve Makine Öğrenmesi ile Model Önerisi</i>	Güner Altan	2022	Banka Kurumsal Kredi Başvuru Skorlama/Derecelendirme	Yapay Sinir Ağları, Naif Bayes, KNN, Lojistik Regresyon, Gradyan Güçlendirme, Aşırı Gradyan Artırma, Rastgele Orman
SONUÇ/BULGU	Çalışmada, doğruluk skoru en yüksek olan rastgele orman olmuştur. Doğruluk skoru, eğitim modelinde %83,1 ve test setinde %82,5 olmuştur. Modelin ROC-AUC skoru %78 çıkmıştır. Diğer modeller için test seti doğruluk oranı sırasıyla; aşırı gradyan artırma %81,82, gradyan artırma %77,5, lojistik regresyon %60, k-en yakın komşu algoritması %61,25, naif bayes %66,25, yapay sinir ağları %61,25'tir. Modelde en çok etkili olan bağımsız değişken dönem net karıdır. Rastgele ormanın F1 skoru %85,71 çıkmıştır. Ayrıca, firmaların bilanço verilerine dayanarak denetimsiz öğrenme yöntemleri kullanılmıştır. Çalışmada firmaların belirlenen başarısızlık kriterlerine göre değerlendirme yapılmıştır. Finansal ve finansal olmayan veriler üzerine belirlenecek başarı kriterlerinden farklı bir model oluşturulabileceği ileri sürülmüştür.			
<i>A Comparative Study of Corporate Credit Ratings Prediction with Machine Learning</i>	Seyyide Doğan, Yasın Büyükkör ve Murat Atan	2022	<i>Banka Ticari Kredi Derecelendirme</i>	XGBoost, DVM, Karar Ağaçları, Lojistik Regresyon, Rastgele Orman ve KNN
SONUÇ/BULGU	Tüm sektörlerin yer aldığı veri setinde destek vektör makineleri %74,17 ile en iyi doğruluğu veren olmuştur. İkincil sırada 74,10% yakın değeri ile aşırı gradyan artırma yer almaktadır. K-en yakın komşu algoritması ve karar ağaçları en düşük performansa sahiptir. 3 farklı sektördeki veri setlerinde en baskın yöntem %82,8, 69,11% ve %66,16 lojistik regresyon olmuştur. Her sektöre nominal bir değişken atandığında tüm veri seti için destek vektör makineleri, Lojistik regresyon, rastgele orman ve aşırı gradyan artırma yöntemlerinin hepsinin doğruluk oranı %73 ile aynı çıkmıştır ve sınıflandırma başarılarında anlamlı bir farklılık görülmemiştir. Ayrıca, üretim firmaları özelinde tüm modellerin %80 üzerinde doğruluk değeri vermesine karşın, inşaat ve taahhüt ile pazarlama sektörlerinde tüm modellerin %70'in altında, %69,11 ile %59,20 arasında olması dikkat çekmektedir. Sektör bazlı ayrıştırma bazı sektörlerin tahmin başarısını artırırken bazılarınınkini olumsuz etkilemiştir. ANOVA testi ile tüm veri seti için yöntemlerin doğrulukları arasında bir farklılık olup olmadığına bakılmış ve post-hoc (Tukey – HSD) uygulandığında karar ağaçlarının tüm yöntemler ile farklılığı bulunurken; destek vektör makineleri, lojistik regresyon, rastgele orman ve aşırı gradyan artırma arasında fark bulunmazken, k-en yakın komşu yöntemi ile destek vektör makineleri ve aşırı gradyan artırma yöntemleri arasında fark bulunmuştur.			

BAŞLIK	YAZAR	YIL	GENEL KAPSAM	METOT
<i>Kredi Temerrüt Riskini Tahmin Etmede Makine Öğrenme Algoritmalarının Karşılaştırılması</i>	Toprak Enes Tütüncü ve Sevda Gürsakal	2023	<i>Banka, Bireysel Ev Kredisi Temerrüt Riski Skolama</i> <i>Kaggle Veri Seti</i>	Gradyan Artırma, Yapay Sinir Ağları, Lojistik Regresyon, Rastgele Orman, Karar Ağacı, Destek Vektör Makineleri, K-En Yakın Komşu ve WOE (Kanıt Aralığı Dönüştürülmüş) Lojistik Regresyon
SONUÇ/BULGU	Çalışmada tahminleme yeteneği en iyi olan modelin belirlenmesi amaçlanmıştır. Sınıflandırmada en iyi model performansı için kesinlik ölçüsü ve F1 skoru baz alındığında gradyan artırma algoritmasının verdiği bulunmuştur. Temerrüde düşen müşteriler için Tip II hata oranı açısından hassasiyet değeri ölçüsüne göre %68,09 ile en başarılı olan yine gradyan artırmadır. Onu, %67,73 oranı ile yapay sinir ağları ve %67,10 oranı ile WOE'li lojistik regresyon yöntemi takip etmektedir. Ek olarak, temerrüde düşmeyen müşterilerin tespit edilmesinde Tip I hataya göre hesaplanan özgüllük ölçüsünde %70,23 ile rastgele orman en başarılı performansı göstermiştir. ROC eğrisine göre k-en yakın komşu algoritması diğer modellerden farklı olarak %62 ile en düşük sonraki değeri olan %72'nin altında düşük bir başarı göstermiştir. Bu değerlendirmeye göre de en başarılı yöntem gradyan artırmadır.			
<i>Credit Risk Prediction Based on Psychometric Data</i>	Eren Duman, Mehmet S. Aktas ve Ezgi Yahsi	2023	<i>Banka, Bireysel Kredi Riski</i>	Lojistik Regresyon, Rastgele Orman, KNN ve DVM
SONUÇ/BULGU	Çalışmada, bireysel kredi riskini psikometrik verilerin nasıl etkilediğini incelemiştir. Müşteri kredibilitesini, karakter özellikleri ve para yönetimine ilişkin tutumlarına göre değerlendirmiştir. Lojistik regresyon, rastgele orman, k-en yakın komşu ve destek vektör makineleri algoritmalarının model performansını ölçen doğruluk değerleri ve F1 skorları aynı ve iyi seviyede çıkmıştır; karar ağaçlarının diğer modellere göre daha düşük performans göstermiştir. Çıkan performans değerleri bu modellerin yüksek doğruluk değerleri ile kredi riskini psikometrik veriler ile ölçebilmek için uygun olduğu görülmüştür. İkili sınıflandırma tahminlerinin genel kalitesini ölçen MCC (Matthew's Korelasyon Katsayısı) değerlerine göre tüm modellerin sınıflandırma doğruluğunda iyi performans gösterdiği belirtilmiştir.			

Kaynak: Yazar tarafından oluşturulmuştur.

3.4. Çalışmanın Önemi

Kredi risk değerlendirme süreçlerinde, finansal kuruluşlar kadar güçlü olmayan kurumların etkili ve hızlı karar almalarını sağlayabilecek bir modelleme çalışması yapılmıştır. Öte yandan, finansal kuruluşlara ait çalışmaların ağırlıklı olduğu makine öğrenmesini baz alan kredi risk literatüründe, finansal olmayan firmalar arasında yapılan ticari işlemleri baz alan ve firmanın müşterilerini her bir yeni siparişi için kredi riskini değerlendirecek herhangi bir

çalışmaya rastlanılmamıştır. Bu amaçla, TL üzerinden açılan mevduatlara uygulanan faiz oranı, sektörel güven endeksi, sipariş sıklığı, şube sayısı, operasyonel ve finansal güç skorunu gösterir segment adlı farklı değişkenler kullanılmıştır. Denetimli öğrenme algoritmaları kullanılarak torbalama, yükseltme, destek vektör makineleri ve k-en yakın komşu yöntemlerinin performanslarının da karşılaştırılmasına olanak tanıyan Tezin, sonraki araştırmalar için fayda sağlayacağı ve özel sektöre katkısının olacağına inanılmaktadır.

Ayrıca, çalışmanın belirlenen araştırma kapsamı çerçevesindeki popüler metotlar için kredi riskine ait istatistiki geleneksel yöntemler ve makine öğrenmesi algoritmalarına ait detaylı bir literatür incelemesi sunulmuştur.




BÖLÜM 4: UYGULAMA

4.1. Çalışmanın Yöntemi

Uygulamada, makine öğrenmesi metotlarından destek vektör makineleri, k-en yakın komşu algoritması, rastgele orman, aşırı gradyan artırma (XGBoost) ve gradyan artırma yöntemleri kullanılmıştır. Bu yöntemler torbalama, yükseltme ve istatistik temelli klasik algoritmaların karşılaştırılabilmesi için tercih edilmiştir. Böylelikle, oldukça yeni sayılabilecek metotların ve alandaki temel uygulamaların performansı değerlendirilebilecektir. Çalışmada, Python program dili kullanılan en temel araç olup SQL (Yapılandırılmış Sorgu Dili) ve MS Excel uygulamalarından da yararlanılmıştır. Kurumsal kaynak planlama (ERP) veri tabanı üzerinden derlenen veriler, veri ön işleme ve özellik mühendisliği aşamalarından geçerek eğitim setine girecek nihai değişkenler belirlenmiş ve algoritmaların performansları karşılaştırılmıştır. Çalışmanın esas amacını oluşturan müşterinin bir sonraki siparişinde ödemelerini vadesinde yapıp yapmayacağını tahmin etmek için hedef değişkenimiz geç ödeme olarak belirlenmiştir ve nihai çıktımız olarak öngörülmesi amaçlanmıştır. Araştırma sorumuz ikili sınıflandırma problemi olduğu için geç ödeme hedef değişkeninin 1 olması halinde vade aşımının mevcut olduğu ve 0 olması halinde zamanında ya da vadesinden erken ödendiğini anlamına gelecek şekilde etiketlenmiştir.

Aşağıda (Şekil 4.1) uygulamaya ait süreç aşamalarına yer verilmiştir. Sürecin daha detaylı akış şeması ise Ekler kısmında yer almaktadır.

Şekil 4.1. Model Uygulama Metodolojisi



4.2. Uygulama Öncesi Süreç

Çalışma kapsamında, MS Excel kurum içi raporları, ERP sistemine ait SQL (Yapılandırılmış Sorgu Dili) veri tabanı, TCMB EVDS (Elektronik Veri Dağıtım Sistemi) ve TÜİK (Türkiye İstatistik Kurumu) istatistik veri portalı üzerinden elde edilen veriler modelin eğitim aşamasına hazır hale gelmesini sağlamak için keşifçi veri analizi (EDA), veri ön işleme ve özellik mühendisliği süreçlerine tabi tutulmuştur. Toplam 23 adet değişkenin, 7 tanesi ekonomik göstergelerden oluşmaktadır. T.C. Merkez Bankası elektronik veri dağıtım sistemi üzerinden dolar kuru, politika faizi, mevduatlara ve ticari kredilere uygulanan faiz oranları verileri alınmıştır. TÜİK istatistik veri portalı üzerinden enflasyon, yurt içi üretici fiyat endeksi ve sektörel güven endeksi verileri temin edilmiştir. Diğer değişkenler, müşterilerin işletme profili bilgileri, operasyonel ve finansal yetkinlik kapsamında kurum içi skorum kriteri, ürün satış bilgileri, ödeme geçmişi ve teminat bilgilerinden oluşmaktadır. Finansal ve finansal olmayan verilerden bu değişkenler veri işleme aşamasında değişerek nihai 19 bağımsız değişken olacaktır.

Çalışma kapsamında incelenen değişkenlere ait bilgilere aşağıda yer verilmiştir.

i. Müşteri Bilgileri:

MUSTERI_ID: Müşterileri tanımlamak için atanan benzersiz değerlerdir. Her bir ticari kimlik için ayrı bir akıllı referans kodu kullanılmaktadır.

ACILIS_TARIHI: Müşteri ile ticari faaliyete başlanan ilk tarihtir. Müşteri ile yürütülen ticari faaliyet yılı bilgisinin modele etkisinin gözlemlenebilmesi adına önemli bir kriter olabilir.

SEGMENT: Müşteri ile yapılacak ticari faaliyet öncesinde temin edilen ve mevcut durumunu dikkate alan bazı bilgileri içeren kurum içi bir skorumdur. Skorumda, müşterinin finansal gücü, operasyonel yetkinliği ve iş birliği seviyesi gibi farklı bilgilerden oluşan bir segmentasyondur. Subjektif değerlendirmeye ait bir kriter olarak çalışma kapsamında yer alacaktır.

MUSTERI_TUR: Firmanın tüzel kişiliğini gösterir şekilde ticari ya da şahıs firması kırımı olarak ikiye ayrılmıştır.

MUSTERI_BOLGE: Bölgesellik etkisinin gözlemlenebilmesi adına müşterilerin vergi levhasında yer alan resmi adreslerinin bulunduğu il bilgisidir.

SUBE_SAYISI: İşletmenin faaliyet gösterdiği mağaza, şube ya da diğer satış noktalarına ait sayıdır.

ALT_SEKTOR: Müşterinin ticari faaliyet alanını ifade eder.

ii. Ödeme ve Satış Bilgileri:

VADE_SURESI: Müşterinin ödeme tercihi ve ürün bilgisine göre belirlenmiş vade şartıdır.

VADE_TARIHI: Müşteri ile anlaşılan ödeme tarihidir.

ODEME_TARIHI: Satış faturasına karşılık gelen tahsilat işleminin tipine göre firmanın hesaplarına geçiş tarihidir.

VADE_ASIM: Uygulanan vade ile gerçekleşen vade arasındaki fark gündür. Erken ya da geç ödeme olabilir.

ODENEN_TUTAR: Faturadaki borcun ödenen kısmına ait tutardır.

FATURA_ID: Satış faturalarına atanan benzersiz değerlerdir. Her bir fatura için ayrı bir akıllı referans kodu kullanılmaktadır.

URUN_KATEGORI: Satış faturasının içerisinde yer alan ürünlere ait kategori bilgisidir. Her kategorinin ayrı finansal koşulları bulunmaktadır. Çalışma kapsamında tercih edilen ürünün geç ödemeye etkisinin olup olmadığı önemli bir kriterdir.

FATURA_TARIHI: Satış faturalarına ait resmi tarih bilgisidir.

iii. Teminat Bilgileri:

MUSTERI_TEMINAT_TUTAR: Banka teminat mektubu, kefalet çeki ve garanti sözleşmesi gibi farklı teminat tiplerine göre alınabilen müşteri bazındaki toplam teminat tutarıdır.

iv. Ekonomik Veriler:

ORT_D_KUR: Aylık ortalama Dolar / TL kurudur.

TUFE: Aylık Tüketici Fiyat Endeksi

YI_UFE: Aylık Yurtiçi Üretici Fiyat Endeksi

VRFO: TCMB 1 Hafta Vadeli Repo Faiz Oranları

VAD_MEV_AKIM: 1 Aya Kadar Vadeli (TL Üzerinden Açılan Mevduatlar) (akım %)-Düzey

PTSGE: Sektör Güven Endeksi

TIC_KRE: Ticari Krediler (TL Üzerinden Açılan) (Tüzel Kişi KMH ve Kurumsal Kredi Kartları Hariç) (Akım Veri, %)

Farklı kaynaklardan elde edilen veriler tek bir ham veri seti oluşturabilmek için Python'da konsolide edilmiş ve çalışmalara bu veri seti üzerinden devam edilmiştir. Ekonomik veriler, fatura tarihinin dönemine göre ilişkilendirilmiştir. Modele girecek nihai değişken bilgilerine bu aşamadan sonra yer verilecektir. Araştırma verileri gizli tutulacağından bu kısımda detaylı bilgi paylaşamamaktadır.

4.2.1. Keşifçi Veri Analizi (EDA)

Herhangi bir veri setini uygun bir şekilde analiz etmek için ilk değerlendirme verilerin karakteristik özellikleri olmalıdır (Helsel ve Hirsch, 2002). Keşifçi veri analizi (EDA), kalıpları keşfetmek, anormallikleri tespit etmek, hipotezi test etmek ve özet istatistikler ve grafik temsilleri yardımıyla varsayımları kontrol etmek için veriler üzerinde ilk araştırmaları gerçekleştirmenin kritik sürecini ifade eder (Patil, 2018). Böylelikle göz ile yakalanamayacak yapıların ortaya çıkarılması (Keskin, 2017) ve uygun modellerin seçimine rehberlik etmesi amaçlanır (Carranza, 2009; Velleman ve Hoaglin, 1981, akt. Camizuli ve Carranza, 2018).

Veri setlerini özetlemek için tanımlayıcı istatistikler, verilerin varyasyonu ve merkezi eğilimlerinin anlaşılması ve aykırı değerlerinin tespiti için kutu grafikleri, değişkenlere ilişkin ilişkilerin anlaşılabilmesi için dağılım grafikleri ya da temel bileşen analizi gibi yöntemler kullanılabilir. Uzman olmayanlar için oldukça kompleks olan bu süreç yapılandırılmış sorgu ya da komut dosyası dillerini bilmeyenler için süreci basitleştirmek ve keşfetme süresini azaltmak için çeşitli arayüz ve sistemler tasarlanmıştır (Milo ve Somech, 2020). Özellikle, makine öğrenmesi aşamasındaki ilerlemeler keşifçi veri analizini kolaylaştırmakla kalmayıp aynı zamanda otomatikleştirmek için fırsatlar oluşturmuştur (Milo ve Somech, 2020).

Değişkenlerin oluşturulması aşamasında kategorik ve numerik veri ayrımlarına dikkat edilmesi yüksek kardinalitesi olan değişkenler için boyut özelliklerinin yeniden sınıflandırılması gibi hususlar modelin performansını arttıracaktır.

Bu aşamada, veri tipleri analiz edilerek değişkenler oluşturulmuş; verilerin dağılımları, tanımlayıcı istatistikleri ve korelasyon analizleri incelenmiştir. Müşterilere ait ACILIS_TARIHI değişkeni kullanılarak firma ile ticari faaliyetlerini sürdürdükleri yıl verisi için MUSTERI_YIL değişkeni oluşturulmuştur.

4.2.2. Veri Seti ve Veri Ön işleme

Veri ön işleme süreci yöntemleri ile veri setindeki kusurlar, tutarsızlıklar veya fazlalıklar giderilerek güvenilir bir şekilde kullanılabilecek veri elde etmek mümkündür (García vd., 2016). Çeşitli disiplinleri içeren bu sürecin ilki veri dönüştürmeyi, entegrasyonu, temizlemeyi ve normalizasyonu kapsar (García vd., 2016). İkinci kısmı ise özellik seçimi, örnek seçimi ve ayırıştırma ile verileri daha düzenli hale getirmeyi amaçlar (García vd., 2016). Özellikle, makine öğrenmesinin sınıflandırma yöntemlerinde hem performansı hem de doğruluğu artırır (Moreira vd., 2018). Gerçek hayat verilerinin genellikle gürültülü ya da başka sorunlara sahip olması nedeniyle (Rahman, 2019) modellerin performansını iyileştirmeyi amaçlayanlarca giderek daha önemli hale geldiği söylenebilir.

i. Eksik Gözlem Analizi

Eksik veri, veri setinde olması beklenen ancak kullanıcı yanıt hatası, yazılım hatası ya da diğer nedenlerle bir gözlemde mevcut olmayan veri parçası olarak tanımlanabilir (Thomas ve Rajabi, 2021). Taraflı ya da hatalı çıkarımlara sebep olabileceğinden göz ardı edilmemesi gerekmektedir (Thomas ve Rajabi, 2021). Kayıp veri dağılımlarının rastlantısallığının kontrol edilmesi amacıyla ısı haritaları kullanılabilir. Farklı sütunlar arasındaki değerlerin korelasyonunu gösteren korelasyon matrisleri görselleştirmek için kullanılır. Böylelikle, eksik değerler arasında bir örüntünün olup olmadığı görülebilir.

Veri setimizde, eksik gözlem değerlerine sahip değişken bulunmamaktadır. Ancak, teminatı veya şubesi olmayan müşterilerde ilgili verilere ait bir giriş yapılmadığından veri tabanından çekilen bilgilerde boş değerler gelebilmektedir. Bu eksiklik, sistemsel ya da farklı bir hatadan kaynaklanmayıp tüm müşteriler ile teminatlı çalışılmadığı ya da her firmanın şubesi

olmadığı için olağan bir durumdur. İlgili boş değerlere sıfır değeri atanarak bu sorun giderilmiştir.

ii. Aykırı Değer Analizi ve Baskılama Yöntemi

Verilerin genel eğitiminden sapan ya da diğer gözlemlerde oldukça farklı değerlere sahip olan aykırı değerler dağılımın kuyruk kısmında yer alırlar (Nacar ve Erdebilli, 2021). İstatistiksel literatüre göre “bir veri kümesinin geri kalanı ile tutarsız görünen gözlemdir” (Barnet ve Lewis, 1978; akt. Escalante, 2005).

Aykırı değer tespiti ile verilerde beklenen davranışa uymayan kalıpların düzeltilmesi için veri seti ve ilgili sektör ya da konu hakkında bilgi sahibi olunması gerekmektedir (Nacar ve Erdebilli, 2021). İlk zamanlarda, parametrik istatistiksel modellerin eğitim verilerine uyumunu arttırabilmesi için veri temizliği ile gerçekleştiriliyor olsa da gerçek hayat senaryolarına uygulanabilecek yüksek performanslı teknikler için yoğun araştırmalar yapılmaktadır (Singh ve Upadhyaya, 2012).

Teminat, vade aşım, ödenen tutar ve şube sayısı değişkenlerindeki potansiyel aykırı değerleri silmek bilgi kaybına yol açabileceğinden baskılama yöntemi kullanılmıştır. Baskılama yönteminin çeşitli aşamaları mevcuttur:

Üst ve Alt Limit Değerlerini Belirleme

Üst ve Alt Limit Değerlerine Göre Aykırıları Gözlemleri Yakalama

Q1 ve Q3 Çeyrekler Açıklığının Bulunması

Yakalanan Aykırı Gözlemleri Üst ve Alt Limit ile değiştirme

Elimizdeki veri setinde eşik değerleri bulmak için çeyrekler açıklığı yöntemi kullanılmıştır.

iii. Kategorik Verilerin Sayısallaştırılması

Makine öğrenmesi algoritmalarında kullanılan veri setlerindeki kategorik sınıflara sahip özniteliklerin, sayısal veri tipi ile ifade edilmesi gerekir. Bunun için etiket kodlama (label encoding) ve tek sıcak kodlama (one-hot encoding) teknikleri kullanılabilir. Verilere bağlı olarak, etiket kodlaması ağaç temelli olmayan algoritmalarda sorun oluşturabilir.

Çalışmamız kapsamında, kategorik özellikleri sıralı olan değişkenimiz için sıralı kodlama ve kategorik özellikleri sıralı olmayan değişkenlerimiz için tek sıcak kodlama yöntemi uygulanmıştır.

iv. Hedef değişkenin belirlenmesi

Vade aşım durumuna göre geç ödeme durumu bilgisi çıkarılarak hedef değişken belirlenmiştir. Geç ödeme hedef değişkeninin ‘1’ olması halinde borcun belirlenen ödeme tarihinden daha sonra yapıldığı; ‘0’ olması halinde ise zamanında ya da erken yapıldığı anlamına gelmektedir.

v. Korelasyon Analizi

Korelasyon en geniş anlamıyla değişkenler arasındaki ilişkinin ölçüsü olarak tanımlanabilir (Schober vd., 2018). Bir değişkenin büyüklüğündeki değişiklik, ilişik olduğu başka bir değişkenin büyüklüğündeki değişiklik ile aynı olması halinde pozitif korelasyon, ters yönde olması halinde negatif korelasyon vardır (Schober vd., 2018).

Çalışma kapsamında en yüksek korelasyonların ekonomik veriler arasında olduğu görülmekle birlikte modelden çıkarılması gereken bir değişken olmamıştır.

4.2.3. Özellik Mühendisliği

Makine öğreniminin veri hazırlığı için merkezi bir görev olan özellik mühendisliği verilen özelliklerden uygun özelliklerin geliştirilerek tahmin performansını geliştirir. Bu amaçla gerçekleştirilen işlemlere aşağıda yer verilmiştir.

- Teminat verilerinde, müşterilerin toplam teminat tutarları için uzmanlar tarafından görüş alınarak belirlenen tutar aralıklarında farklı segmentler oluşturulmuştur. Bu değişken çalışmada MUSTERI_TEMINAT_DURUMU olarak adlandırılacaktır.
- Şube sayısı verileri için uzmanlar tarafından görüş alınarak belirlenen farklı segmentler oluşturulmuştur.
- 10 adet faturadan daha az olan müşteri verilerinden anlamlı bir sonuç çıkmayacağı için veri setinde oldukça az sayıda oldukları da göz önüne alınarak çıkarılmıştır.

- Müşterinin hangi sıklıkla alışveriş yaptığını gözlemleyebilmek için son siparişin üzerinden geçen gün verisi oluşturulmuştur. İlgili değişkenin geç ödemeye etkisi olup olmadığı değerlendirilecektir. Bu değişken, çalışmada SON_SIPARIS_GUN olarak adlandırılacaktır.
- Faturaya ait ödemelerin birden fazla olması nedeniyle öncelikle faturaya ait toplam ödenen fatura tutarı hesaplanmıştır. Bu değişken TOPLAM_TUTAR olarak adlandırılacaktır.
- Faturaya ait ödemelerin birden fazla olması ve her ödemenin zamanında yapılıp yapılmadığı farklı olduğu için öncelikle faturaya ait ortalama vade aşım ya da erken ödeme değerleri bulunmuştur. Sonrasında bu değerler bir sonraki faturasında değerlendirilebilmek üzere geçmiş alımlarına ait müşteri bazında ortalama vade aşım (ya da erken ödeme) değeri bulunmuştur. Böylelikle, müşterinin yeni bir siparişinden önceki alımlarına ait ödeme durumu gözlemlenebilecektir. Bu değişken, çalışmada ORT_VADE_ASIM olarak adlandırılacaktır.

Modele girecek nihai değişkenler içerisinde ID değeri içeren MUSTERI_ID ve FATURA_ID değişkenleri ile yalnızca veri ön işleme ve özellik mühendisliği aşamaları için kullanılan değişkenler çıkarılmıştır.

i. Özellik Ölçekleyici

Bu aşamada, veri setindeki sayısal değişkenlere ait özniteliklerimiz farklı ölçeklerde olduğundan dolayı standart ölçekleyici uygulaması yapılmıştır. Özellik ölçeklendirme yöntemlerinden biri olan bu yöntem, veri seti dağılımının ortalama değerini 0 ve standart sapmasını 1 olacak şekilde dönüştürür (Thara vd., 2019). Değerin dönüştürülmüş hali, ortalama değer orijinal değerden çıkarılarak standart sapmasına bölünmesi ile elde edilmektedir (Thara vd., 2019). Özellik ölçekleme bilgi kaybetmeden öznitelikleri ortak bir aralığa ölçeklendirmeyi amaçlar (Mahalakshmi ve Sujatha, 2023). Bu şekilde makine öğrenmesi algoritmalarının doğru bir şekilde çalışmasına yardımcı olur ve veri setinin daha iyi yorumlanmasını sağlar.

Tüm bu süreç aşamaları sonrasında hedef değişken dahil nihai olarak toplam 20 adet değişken bulunmaktadır.

4.3. Uygulama ve Değerlendirme

Bu bölümde, eğitime hazır hale gelen veri setinin makine öğrenmesi algoritmaları uygulanan modellerine ait sonuçlar incelenmiştir. Model performansı, Tip I ve Tip II hata, doğruluk ve ROC eğrisi değerlerine göre değerlendirilmiştir.

4.3.1. Veri Setinin Eğitim-Test Seti Olarak Bölünmesi

Sınama seti (Hold-Out) ya da test seti değerlendirmesi (test set estimation) (Omary ve Mtenzi, 2010), tartışmasız en basit model değerlendirme tekniğidir (Raschka, 2018). Öncelikle, etiketli bir veri setini rastgele olacak şekilde birbirinden münhasır iki alt kümeye, test seti ve eğitim seti olarak böler (Raschka, 2018). Çalışmamızda da bu yöntem kullanılarak eğitime hazır veri seti %80 eğitim ve %20 test verisi olarak ayrılmıştır. Kurulan modelde tahmin edilen etiketler, test setinin doğruluk etiketleri ile karşılaştırılarak tahmin doğruluğuna ilişkin sonuçlar incelenmiştir.

4.3.2. Modelin Uygulanması ve Kalitesinin Değerlendirilmesi

Çalışma kapsamında incelenen beş makine öğrenmesi yöntemi Python program dili aracılığı ile uygulanmıştır. Bu aşamada, modeller test seti kullanılarak kredi riski tahmin sonuçlarının değerlendirilmesinde yaygın olarak kullanılan sınıflandırma ve performans ölçütleri kapsamında incelenmiştir.

i. Karmaşıklık Matrisi

Hata matrisi olarak da bilinen karmaşıklık matrisi (Sharma vd., 2022), ikili ya da çoklu sınıflandırma problemlerinde kullanılan yaygın bir ölçümdür (Singh vd., 2021). Model sınıflandırmalarına ait tahminlerin ne kadarının hatalı ve doğru olduğunun görsel ve özet bir temsilini verir (Tiwari, 2022) (bkz. Şekil.4.2.).

Karmaşıklık matrisi, sınıflandırıcının ölçüm metriklerini tanımlamak için kullanılan gerçek pozitif, hatalı pozitif, gerçek negatif ve hatalı negatif olmak üzere dört temel özellikten oluşur (Singh vd., 2021). Bu özelliklerin detayı ve modelin tahmin gücünü değerlendirmeye katkıları aşağıda ayrıca belirtilmiştir.

Şekil 4.2. Karmaşıklık Matrisi

		TAHMİN EDİLEN SINIF	
		0 Geç Ödeme Yok	1 Geç Ödeme Var
GERÇEK SINIF	0 Geç Ödeme Yok	Gerçek Negatif (GN)	Hatalı Pozitif (HP) TİP I HATA
	1 Geç Ödeme Var	Hatalı Negatif (HN) TİP II HATA	Gerçek Pozitif (GP)

Gerçek Pozitif, doğru şekilde sınıflandırılmış geç ödeme yapılan işlemlerin sayısını temsil eder.

Hatalı Pozitif, yanlışlıkla geç ödeme olarak sınıflandırılan ancak vade aşımı yapılmayan işlemlerin sayısını temsil eder. Hatalı pozitif aynı zamanda Tip I hatayı temsil etmektedir. Çalışmamızda bu hata tipi borcun zamanında ya da daha erken ödemesi yapılacak farklı bir siparişe onay verilmemesi ile ciro kaybına sebep olabilir. Sürecin getirdiği kayıp alternatif fırsat maliyetlerinin yanında müşteri ilişkileri de olumsuz etkilenebilir. Bu durum ilerleyen vadede piyasa rekabetinde geriye düşmeye ve pazar payı kaybetmeye dahi sebep olabilir.


Gerçek Negatif, ödemesinin vadesinde ya da daha erken yapıldığı diğer bir ifadeyle vade aşımı yapılmayan işlemlerin uygun bir şekilde geç ödeme yapmayan grupta sınıflandırılmış işlemlerin sayısını temsil eder.

Hatalı Negatif, ödemesinin vadesinde yapılmadığı başka bir deyişle müşterinin vade aşımli işlemlerinin hatalı bir şekilde geç ödeme yapmayan grupta sınıflandırılmış işlemlerinin sayısıdır. Hatalı negatif, aynı zamanda Tip II hata olarak da bilinir. Çalışmamızda bu hata tipi borcun zamanında ödenmeyecek sipariş talepleri için ürün satışına onay verilmesi ile hatalı karar almaya sebep olacaktır. Bu durum, stokların ve işletme sermayesinin etkin kullanımının önüne geçer ve geç ödeme tutarına göre nakit akışında ciddi olumsuzluklara sebep olabilir.


Özellikle, enflasyonist ortamda yapılan bu hata, ek kazanç sağlayacak farklı finansal yatırım kararlarına ayrılacak kaynağı da olumsuz etkileyebilir. Ayrıca, bu hata müşterinin iflas riski taşıdığı durumlarda müşterinin herhangi bir teminatlandırması yoksa eğer süreç ek maliyetlere sebep olabilir.

Modellerin karmaşıklık matrisleri aşağıda belirtilmiştir.


Şekil 4.3. Destek Vektör Makineleri Karmaşıklık Matrisi




Şekil 4.4. K- En Yakın Komşu Karmaşıklık Matrisi




Şekil 4.5. Rastgele Orman Karmaşıklık Matrisi



Şekil 4.6. Gradyan Artırma Karmaşıklık Matrisi



Şekil 4.7. Aşırı Gradyan Artırma Karmaşıklık Matrisi



Kredi riski skorlama modelleri genellikle iki tip hata yapabilir. İlki Tip I hata olarak adlandırılır ve iyi bir kredinin hatalı olarak kötü kredi olarak sınıflandırılması (Abdou ve Pointon, 2011) başka bir ifadeyle, borcun düşük riskli olmasına karşın modelde yüksek riskli gösterilmesidir (Keenan ve Sobehart, 1999). Bu nedenle, düşük riskli bir borcun reddedilmesi anlamına gelir. Bir diğeri ise Tip II hata olarak adlandırılır ve kötü bir kredinin hatalı olarak iyi kredi olarak sınıflandırılması (Li ve Zhong, 2012) başka bir deyişle modelin yüksek riskli olmasına karşın düşük riskli gösterilmesidir (Keenan ve Sobehart, 1999). Bu durum, borcun yüksek riskli olmasına rağmen kabulü anlamına gelmektedir.

Alanda genel olarak Tip II hatalarının, Tip I hataya bağlı olanlardan daha maliyetli olduğuna inanılmaktadır (Baesens vd., 2003). İyi bir krediyi reddetmenin daha az maliyetli olabileceği kabul edilmiş olsa da alternatif kredinin yüksek kredi riski taşıması çok maliyetli olduğunda kaybedilen gelirin tam olarak geri kazanılması mümkün olmayabilir (Nayak ve Turvey, 1997).

Tip I hata ile Tip II hata arasındaki göreceli yanlış sınıflandırma maliyeti 5 kata kadar çıkabilmektedir (West, 2000). Ancak, her iki durumda da borç veren beklenen karda kayıp yaşayacaktır. Tip II hata; anapara kaybına ve firma itibarının olumsuz etkilenmesine sebep olabilir (Koh, 1991). Kredi zararlarına ek olarak, idari masraflar, yasal ücretler gibi gelebilecek ek maliyetler, teminat varlıklarının satışından tam olarak geri alınamayabilir (Nayak ve Turvey, 1997). Tip I hatanın yüksek seviyelerde olması firmanın ticari riske maruz kaldığının göstergesi niteliğindedir. Borç veren iyi bir krediyle ilgili gelirlerden vazgeçmiş olur ve beklenen kâr alternatif krediye bağlanır. Burada dikkat edilmesi gereken husus iyi olarak sınıflandırılacak bir borçludan vazgeçilen kâr ve bir sonraki "bilinmeyen" borçludan beklenen kâr; bir sonraki borçlunun düşük ya da yüksek kredi riski olabileceği ihtimalidir (Nayak ve Turvey, 1997).

Ayrıca, farklı kredi riski (temerrüt, iflas, kredi verme vb.) sınıflandırma çalışmalarında hedef değişkenin atandığı pozitif ya da negatif sınıflandırma değerinin farklılaşması, literatürdeki Tip I ve Tip II hata olarak adlandırılan durumlara ait maliyetlerin alandaki karşılıklarının farklılaşması anlamına gelmektedir. Araştırmacıların burada Tip I ve Tip II hata tanımlarının açıklamalarına yer vermesi gerektiği düşünülmektedir. Bu farklılıklar araştırma sorusuna ve araştırmacının yaklaşımına bağlı olarak değişiyor olabilir.

Tablo 4.1. Model Karmaşıklık Matrisi Değerleri ve Tip I ve Tip II Hata


MODEL	GP	GN	HP	HN	TİP I HATA (%)	TİP II HATA (%)
Destek Vektör Makineleri	4232	2214	792	611	%26,3	%12,6
K- En Yakın Komşu	4404	2219	743	483	%25,1	%9,9
Rastgele Orman	4604	2554	419	272	%14,1	%5,6
Gradyan Artırma	4359	2244	729	517	%24,5	%10,6
Aşırı Gradyan Artırma	4504	2491	511	343	%17,0	%7,1

Tablo 4.1. sonuçlarına göre, Tip I hata oranı %14,1 ve Tip II hata oranı %5,6 olan rastgele orman modeli en düşük hata oranlarına sahiptir ve Tip II hata oranı daha düşüktür. Bu durum algoritmanın genellikle birçok karar ağacını bir araya getirerek hatalı negatif oranını minimize etme eğiliminden kaynaklanabilir. Destek vektör makineleri her iki hata tipinde diğer modellere göre en yüksek seviyedeki oranlara sahiptir. Veri setinde ölçeklendirme yapıldığı ve modelinde RBF Kernel fonksiyonu kullanıldığı için bu hata oranlarının destek vektör makinelerinin küçük boyutlu veri kümelerinde başarılı olmasından kaynaklanabilir. Hata oranlarının en düşük olduğu ikinci modelimiz aşırı gradyan artırma olmuştur. Tüm modellerde Tip I hata oranının daha yüksek olduğu görülmektedir.

ii. Alıcı İşletim Karakteristik Eğrisi (ROC Eğrisi)

Alıcı İşletim Karakteristik Eğrisi (ROC Eğrisi) gözlemleri iki kategoriden birine (örneğin geç ödeme var, geç ödeme yok) ne kadar doğru sınıflandırıldığını gösteren iki boyutlu grafiklerdir (Argüello-Prada ve Valencia, 2023). Eğri, herhangi bir eşik değeri için kartezyen düzlemdeki bir noktanın temsil edilmesi diğer bir ifadeyle geç ödeme yapan ve yapmayan borçlular için sınıflandırma puanlarının diğer bir ifadeyle tahmin olasılığının olası dağılımları kullanılarak çizilir (Gigliarano vd., 2014). Böylelikle, karmaşıklık matrisinde yer alan gerçek pozitif oran (faydalar) ve yanlış pozitif oranının (maliyetler) arasındaki göreceli dengeyi temsil eder (Gigliarano vd., 2014). İdeal olan Y eksenini başka bir deyişle gerçek pozitif sol tarafta yer aldığı için en iyi eğri de solda yer alacaktır.

Şekil 4.8. ROC Eğrisi ve AUC




Kaynak: Engelmann ve Hayden (2003) ve Sakri (2022)'den yararlanılarak Yazar tarafından oluşturulmuştur.


Eğrinin altında kalan alan (AUC) modelin ayırt edici gücünü gösteren ve yaygın olarak kullanılan bir ölçümdür ve tüm olası sonuçları toplar (Krzanowski ve Hand, 2009) (bkz. Şekil 4.8). Daha geniş bir AUC alanı daha iyi bir model anlamına gelir.

Modellerin ROC eğrilerine ait görsellere aşağıdaki şekillerde yer verilmiştir.


Şekil 4.9. Destek Vektör Makineleri ROC Eğrisi




Şekil 4.10. K- En Yakın Komşu ROC Eğrisi




Şekil 4.11. Rastgele Orman ROC Eğrisi



Şekil 4.12. Gradyan Artırma ROC Eğrisi



Şekil 4.13. Aşırı Gradyan Artırma ROC Eğrisi



Tablo 4.2. AUC Değerleri

MODEL	AUC
Destek Vektör Makineleri	0,8913
K- En Yakın Komşu	0,9037
Rastgele Orman	0,9675
Gradyan Artırma	0,9126
Aşırı Gradyan Artırma	0.9507

Modellerin AUC değerlerine göre (Tablo 4.2.) en iyi performansı gösteren model rastgele orman %96,75 ve sonrasında %95,07 ile aşırı gradyan artırmadır. Destek vektör makineleri en düşük performansa sahiptir.

iii. Doğruluk, Kesinlik, Duyarlılık ve F1-Skor

Karmaşıklık matrisine bağlı olarak performans değerlendirme ölçütlerinden doğruluk, kesinlik, duyarlılık ve F1 Skor değerleri karşılaştırılmıştır. Bu ölçümlerin açıklamalarına ve model değerlerine (Tablo 4.3) aşağıda yer verilmiştir.

- **Doğruluk**, doğru sınıflandırılan tahminlerin değerini $(GP + GN) / (GP + GN + HP + HN)$ formülü ile ölçümler.
- **Kesinlik**, gerçekte pozitif olan ve bu şekilde sınıflandırılan tahminlerin doğruluğunu $GP / (GP + HP)$ formülü ile ölçümler.

- **Duyarlılık**, belirli bir sınıfa ait örneklerin doğru tahminlenme yeteneğini $GP / (GP + GN)$ formülü ile ölçümler.
- **F1- Skor**, duyarlılık ve kesinlik ölçümlerinin harmonik ortalaması olup $(2 * Kesinlik * Duyarlılık) / (Kesinlik + Duyarlılık)$ formülü ile hesaplanır.

Tablo 4.3. Model Performans Ölçüm Metrikleri

Metrikler		Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
Destek Vektör Makineleri	Geç Ödeme Yok	0,7837	0,7365	0,7594	0,8213
	Geç Ödeme Var	0,8424	0,8738	0,8578	
K-En Yakın Komşu	Geç Ödeme Yok	0,8212	0,7492	0,7835	0,8438
	Geç Ödeme Var	0,8556	0,9012	0,8778	
Rastgele Orman	Geç Ödeme Yok	0,9038	0,8591	0,8808	0,9120
	Geç Ödeme Var	0,9166	0,9442	0,9302	
Gradyan Artırma	Geç Ödeme Yok	0,8127	0,7548	0,7827	0,8413
	Geç Ödeme Var	0,8567	0,8940	0,8749	
Aşırı Gradyan Artırma	Geç Ödeme Yok	0,8790	0,8298	0,8537	0,8912
	Geç Ödeme Var	0,8981	0,9292	0,9134	

Tablo 4.3. sonuçlarına göre, %91,20 ile rastgele orman en yüksek doğruluğa sahiptir. Diğer modellerin doğruluk oranlarına göre sıralaması; aşırı gradyan artırma, k- en yakın komşu, gradyan artırma ve destek vektör makineleridir. Tüm modeller %82'nin üzerinde doğruluk seviyesine sahiptir. K- en yakın komşu ve gradyan artırma algoritmalarının doğruluk seviyeleri yakındır. Rastgele orman geç ödeme olan ve olmayan sınıflardaki tüm ölçüm metriklerinde de en yüksek performansa sahiptir. Destek vektör makineleri yanlış pozitifin hata maliyeti göz önüne alındığında kesinlik ve duyarlılık ölçütlerinde en düşük oranlara sahip olduğu için fırsatların iyi değerlendirilememesine sebep olabilir. Bu nedenle, tercih edilebilir bir yöntem değildir. Ayrıca, pozitif ve negatif değerler eşit dağılmadığından dolayı F1 skor değeri dikkate alınması gereken bir metriktir. Rastgele orman bu metriklerdeki yüksek performansı ile de tercih edilebilir bir yöntem olarak öne çıkmaktadır.

4.3.3. Model Optimizasyonu ve En İyi Modelin Değerlendirilmesi


Modelden en yüksek performansı elde edebilmek için hiper parametre ayarlaması yapılmıştır. Tüm ölçüm metriklerinde en iyi performansa sahip olan rastgele orman algoritması ızgara araması (GridSearch) tekniği ile optimize edilerek yeniden eğitilmiştir. Bu teknik ile

parametrelerin farklı kombinasyonları denenerek doğruluk değerinde en iyi sonuçlar veren hiper parametreler seçilmiştir. Çıkan sonuçlara göre optimize edilmiş model Tablo 4.4.'e göre ilgili metriklerde genel olarak daha iyi performans göstermiştir. Modelin duyarlılığı geç ödeme yapacak grupta daha yüksek çıkmıştır. Geç ödeme olmayan grubun en yüksek duyarlılık seviyesine sahip olduğu için firmanın ciro kaybı yaşamaması açısından en tercih edilebilir model olarak görülmektedir. Modelin ROC eğrisine ait görsele aşağıda yer verilmiştir (bkz. Şekil 4.14.).

Tablo 4.4. En İyi Model Performans Ölçüm Metrikleri

Metrikler		Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
Rastgele Orman	Geç Ödeme Yok	0,9038	0,8591	0,8808	0,9120
	Geç Ödeme Var	0,9166	0,9442	0,9302	
Optimize Edilmiş Rastgele Orman	Geç Ödeme Yok	0,9038	0,8755	0,8895	0,9176
	Geç Ödeme Var	0,9255	0,9432	0,9343	

Şekil 4.14. En İyi Model (Optimize Edilmiş Rastgele Orman) ROC Eğrisi




Tablo 4.5. En İyi Model Tip I ve Tip II Hata, AUC ve Doğruluk Metrikleri

MODEL	TİP I HATA (%)	TİP II HATA (%)	AUC
Rastgele Orman	%14,09	%5,58	0,9675
Optimize Edilmiş Rastgele Orman	%12,45	%5,68	0,9694

Tablo 4.5'e göre modelin Tip I hata oranı azalmış ancak Tip II hata oranında minimal düzeyde artış olmuştur. Ayrıca, AUC değerinde anlamlı bir artış görülmemiştir.

Değerlendirilen tüm modeller içerisinde (Şekil 4.15) doğruluk seviyesi en yüksek olan model rastgele orman modelinin optimize edilmiş hali en iyi model olarak belirlenmiştir.


Şekil 4.15. Modellere Ait Doğruluk Karşılaştırması



4.3.4. En İyi Model İçin Özellik Önemi

Çalışmada en iyi performansı gösteren optimize edilmiş rastgele orman modeli için özellik önem seviyeleri Şekil 4.16'da gösterilmiştir. Modelin tahminlemesinde kullanılan bu unsurlar önem değerinin azalan sıralamasına göre gösterilmiştir (Coşer vd., 2019). Hedef değişkenimizi en çok etkileyen ORT_VADE_ASIM olmuştur. En önemli olan sonraki 5 değişken sırasıyla TOPLAM_TUTAR, VADE_SURESI, MUSTERI_YIL, SON_SIPARIS_GUN ve ORT_D_KUR olmuştur. Bu ilk 6 değişken %91,76 doğruluk oranının yarısından fazlasına tekabül etmektedir. Buradan, müşterilerin satın alma ve ödeme geçmişi ile anlaşma yapılan vade süresinin oldukça önemli olduğu görülmektedir. Müşteriler ile sürdürülen ticari faaliyet süresinin geç ödeme üzerinde etkili olduğu görülmektedir. Modelde yer alan ekonomik değişkenlerden kalan 6 tanesi önem sırasına göre YI_UFE, PTSGE, TUFİE, TIC_KRE, VAD_MEV_AKIM ve VRFO olarak sıralanmaktadır. Dolar kuru ve üretici maliyetleri başta olmak üzere ilgili ekonomik değişkenlerin kurum içi diğer değişkenlerden daha yüksek önem düzeyine sahip olması makroekonomik politikaların ve belirsizlik ortamının ticari faaliyetler üzerinde etkili olduğunu göstermektedir. Bununla birlikte, politika faizinin önem seviyesinin diğer ekonomik değişkenlerden daha düşük çıkarak sıralamada ayrışması, oranların yürütülen politikalara bağlı olarak belirlenmesinden kaynaklanabilir.

Şekil 4.16. Modele En Etkili 35 Değişken



Müşterinin alım yaptığı ürün kategorilerinin ve bulunduğu ilin geç ödeme değişkenine etkisinin bulunduğu tespit edilmiştir. Faaliyet gösterilen alt sektörlerden bir tanesinin modelde daha etkili olduğu ve diğer sektörlerin etkisinin düşük çıktığı görülmüştür. Müşterilerin teminat durumu, şube ağı genişliği, segmenti ve şahıs firması olup olmasının ise diğer değişkenlere göre daha kısıtlı etkisi vardır. Bu değişkenlere önem sırasına göre bakıldığında teminat durumunun ve şube ağı genişliğinin daha önemli olduğu görülmektedir. Müşterinin kurum içi operasyonel ve finansal kalitesi ile iş birliğini ölçümleyen subjektif skorlamanın etkisinin düşük olmasının farklı sebepleri olabilir. Finansal açıdan bakıldığında müşterinin finansal ve operasyonel yetkinliği ile iş birliğinin geç ödemeye olan etkisinin ekonomik konjonktür ve belirsizlik ortamlarına göre şekillendiği söylenebilir. Müşterinin bu yetkinlikleri güçlü olsa dahi enflasyonist ortamda alternatif fırsatları değerlendirmek istemesi sebebiyle ödemelerini geciktirebilir. Ayrıca, müşteri çalışma yılı ve modele etkisi göz önüne alındığında tedarikçi firmanın orta ya da uzun vadeli kâr beklentisi ve pazar payını korumak istemesi sebebiyle vade öteleme taleplerini kabul etmesi veya vade aşımın maliyetine katlanmayı kabul ettiği anlamına gelebilir. Eğer tahsilat politikasında gecikme faizi uygulaması varsa ve müşterinin alternatif kazancından düşükse borç alan taraf da bu yönde tercih yapıyor olabilir. Valör maliyetine ait herhangi bir yaptırım olmaması halindeyse buradaki maliyeti de tedarikçi firma üstlenmiş olacaktır.

BÖLÜM 5: SONUÇ VE ÖNERİLER

Yeni dünya düzeninin getirdiği belirsizlik ortamı, dijitalleşme ve küresel rekabet kurumların maruz kaldığı riskleri daha öngörülemez hale getirmiştir. Finansal piyasalardaki şoklar ve yaşanan ekonomik krizler hızlı bir şekilde küresel etki yaratabilmektedir. Özellikle, pandemi sürecinden etkilenen ticari ilişkiler ve tedarik zincirlerindeki iflas korkusu tüm dünyayı etkisi altına almış; kredi riskinin küresel ve yerel ekonomilerdeki önemini bir kez daha vurgulamıştır. Bu noktada, kredi riski finansal istikrarsızlığa yol açma potansiyeli ve sermaye erişim maliyetlerini etkilemesi sebebiyle kritik öneme sahiptir. Tarihsel olarak yüksek borç yükleri de göz önüne alındığında kredi riskinin etkin bir şekilde değerlendirilmesi kaçınılmaz bir zorunluluk haline getirmiştir. Zira artan borçların sürdürülebilirliği sorun teşkil ettiğinde ülke ekonomileri bu durumdan olumsuz etkilenecektir.

Özellikle, Türkiye gibi dışa bağımlı ve kırılganlıkların fazla olduğu ülkelerde kredi riskinin etkin yönetilmemesi kurumların kârlılıklarını olumsuz yönde etkiler ve nakit akış yönetiminde sıkıntılara sebep olur. Bu nedenle, şirket ödeme yapamama riski yüksek olarak sınıflandırılan ülkemizde kurumların risk iştahlarını iyi belirlemeleri ve müşterilerinin ödeme davranışlarının dış etkenler ile değişebileceğini göz önüne almaları gerekmektedir. Bu kapsamda, yeni bir sipariş alındığında borcun zamanında ödenip ödenmeyeceği ve ödemelere ekonomik verilerin etkili olup olmayacağı sorularına cevap aranmıştır.

Kredi riskinin taşımış olduğu önem sebebiyle literatürdeki çalışma alanı geniş ve kapsamlı olmasına karşın ağırlıklı olarak finansal kuruluşların taşıdığı risk araştırılmıştır ve kurumların kredi riski genellikle mali veriler üzerinden değerlendirilmiştir. Ancak, piyasada bu bilgilere erişmenin zor ve zaman alıcı olması alternatif karar verici sistemleri gerektirmektedir. Ayrıca, mali veriler geçmiş bilgilere dayandığı için hızlı değişimlerin olduğu ortamlarda değişiklikleri yakalayabilmek için yeterli olmayabilir. Bu tezde, bu sorunları gidermek için makine öğrenmesi algoritmaları kullanılarak genel uygulanabilir bir model araştırılmıştır. Bu bağlamda, çalışmanın amacı, özel sektörde faaliyet gösteren finansal bir kuruluş olmayan firmanın ticari ilişki içerisinde olduğu müşterilerin verilerinden ve ekonomik göstergelerden faydalanarak; makine öğrenmesi algoritmaları ile kredi riskini tahmin eden bir model önerisi sunmak ve literatürdeki bu eksikliği gidermektir. Bu kapsamda, analizi yapılan firmanın 2022 yılında çalışmış olduğu 565 adet müşterinin ticari bilgilerinden oluşan 12 adet kurum içi değişken ve dışsal kaynaklı 7 adet ekonomik değişken olmak üzere toplam 19 adet bağımsız değişken kullanılmıştır. Kurum içi verilerden müşterinin kurumsal profili, ödeme, satış ve

teminat bilgilerinden yararlanılmıştır. Bu değişkenler içerisinde mevcut literatürden farklı olarak finansal bilgilerin yanında müşterinin operasyonel yetkinliği, finansal gücü ve gösterdiği iş birliğinin değerlendirilerek sınıflandırıldığı değişkene segment adıyla yer verilmiştir. Benzer şekilde, literatürden farklı olarak müşterinin sipariş sıklığı değişkeni modelde yer almıştır. Ekonomik verilere, TCMB EVDS ve TÜİK istatistik veri portalı üzerinden erişim sağlanmıştır. TL üzerinden açılan mevduatlara uygulanan faiz oranı ve sektörel güven endeksi değişkenleri literatürden farklı olarak çalışmada kullanılmıştır. Araştırma sorumuz ikili sınıflandırma problemi olup geç ödeme hedef değişkenimizin 1 olması vade aşımının mevcut olduğu ve 0 olması zamanında ya da vadesinden erken ödendiğini anlamına gelmektedir. Çalışma kapsamında torbalama, yükseltme, destek vektör makineleri ve k-en yakın komşu makine öğrenmesi algoritmalarının performansları karşılaştırılmış ve özniteliklerin modele etkisi değerlendirilmiştir.

Çalışmada, rastgele orman algoritması en yüksek doğruluk değerine ve Tip I ile Tip II hatada en düşük oranlara sahiptir. Bu nedenle, performans değerlendirme kriterlerine göre en iyi yöntem olarak seçilerek optimize edilmiştir. Literatürdeki çalışmaların sonuçları ile uyumlu bir şekilde başarılı olan rastgele orman algoritmasının, finansal olmayan kurumların kredi risk değerlendirme çalışmaları için de uygun bir yöntem olduğu çalışmamız ile desteklenmiştir. Bir yükseltme algoritması olan aşırı gradyan artırma yöntemi en iyi ikinci yöntemdir. Türkiye'deki literatür çalışmalarında performansı ile öne çıkan gradyan artırma yöntemi çalışmamızda doğruluk değerine göre en düşük ikinci performansa sahiptir. K- en yakın komşu algoritmasının doğruluk seviyesi gradyan artırma ile yakındır. Destek vektör makineleri, en düşük doğruluk seviyesine sahiptir ve yanlış pozitifin hata maliyeti göz önüne alındığında tercih edilebilir bir model olmamıştır.

Modele en etkili olan değişkenler incelendiğinde ilk sırada ortalama vade aşım değişkeni yer almıştır. Bu değişkeni sırasıyla tutar, vade süresi, müşteri ile çalışılan faaliyet yılı, sipariş sıklığı ve ortalama dolar kuru takip etmiştir. %91,76 doğruluk oranının yarısından fazlasına tekabül eden bu değişkenler, müşteri ile yapılan anlaşma şartlarının, ödeme alışkanlıklarının, ticari ilişkinin yürütüldüğü sürenin önemli olduğunu göstermektedir. Bu değişkenleri takip eden sonraki 5 değişkenin tamamı ekonomik verilerden oluşmaktadır. Etki sırasına göre sıraladığımızda üretici fiyat endeksi, sektörel güven endeksi, enflasyon, ticari kredi faizi ve TL mevduatlara uygulanan faiz oranı değişkenleri birbirine yakın seviyede çıkmıştır. Ancak, politika faizinin önem seviyesi diğer ekonomik değişkenlerden negatif ayrılmıştır. Bununla birlikte ekonomik değişkenlerin kurum içi diğer değişkenlerden daha

yüksek önem düzeyine sahip olması, makroekonomik politikaların ve belirsizlik ortamının ticari faaliyetler üzerinde etkili olduğunu göstermektedir. Özellikle, sermaye erişim maliyetinin yüksek olduğu durumlarda borçlu taraflar ödeme aczine düşebilir, vade öteleme talepleri oluşabilir ve hatta iflaslar artabilir. Diğer yandan, yüksek faiz ya da alternatif yatırım araçlarından elde edilecek finansal karın, operasyonel kardan daha fazla kazanç sağlaması tarafları cezbedebilir ve sahip olunan sermayenin farklı alanlarda kullanımı için yönlendirebilir. Bu durum, kredi veren taraflar için kredi riskini arttırabilir ve nakit akış yönetiminde sıkıntılara sebep olabilir. Üretim ve satışların etkilenmesiyle ülke ekonomisine de olumsuz yansımaları olur; borçlanmalar artar, kredi daralması yaşanır, ekonomik büyüme yavaşlar ve istihdam olumsuz yönde etkilenir. Dolayısıyla, firmaların alacak tahsilindeki risklerini iyi yönetebilmeleri hem rekabet güçlerinin artmasını sağlar hem de ülke ekonomisinin istikrarına destek olur.

T. Bellotti ve J. Crook (2009) kredi kartı tipinin ve H. Okur (2020) kredi türünün kredi riskinde önemli olduğunu belirttiği gibi çalışmamızda müşterilerin alım yaptığı ürün kategorilerinin etkisi önemli çıkmıştır. H. Okur (2020) çalışmasında bölge bilgisinin kredi riskinde etkili bir faktör olduğu belirtilmiştir. Müşterinin faaliyet gösterdiği il bilgisi değişkenimiz, bu sonucu destekler şekilde önemli çıkmıştır. Müşterilerin teminat, şube ağı genişliği ve şahıs firması olup olmasının kısıtlı etkisi vardır. Müşterinin kurum içi operasyonel ve finansal kalitesi ile iş birliğini ölçümleyen subjektif skorlamanın etkisinin yüksek olmaması, tahsilat politikaları ve ödeme kararlarının ekonomik konjonktür ve belirsizlik ortamlarına göre şekillendiğini gösterebilir. Müşterinin finansal ve operasyonel yetkinliği yüksek olsa dahi enflasyonist ortamda alternatif fırsatları değerlendirmek istemesi sebebiyle ödemelerini geciktirebilir. Müşterinin çalışma yılı ve modele etkisi göz önüne alındığında tedarikçi firmanın orta ya da uzun vadeli kâr beklentisi ve pazar payını korumak istemesi sebebiyle vade öteleme taleplerini kabul etmesi veya vade aşımın maliyetine katlanmayı kabul ettiği anlamına gelebilir.

Enflasyonist ortam ve krediye erişimin zorlaşması, firmaların kredi riskini arttırmakta ve likidite yönetimi daha önemli hale gelmektedir. Müşteri özelinde doğru ürün satışı, vade yönetimi ve teminat kararlarında alınabilecek hatalı sonuçlar âtıl stoklara ve nakit yönetiminde sorunlara sebep olacaktır. Değişkenliğin hızlı olduğu bu ortamda ticari faaliyet ilişkileri sürdürülürken satış ve tahsilat kararlarının doğru ve hızlı alınması gerekmektedir. Böylelikle, kaynakların daha verimli kullanılması sağlanacaktır. Bu durumda, borç alan ve borç veren tarafların ticari ilişkilerinin sağlıklı yönetimi ülke ekonomisine de katkı sağlayacaktır.

İlerleyen alıřmalar iin farklı rn tiplerine gre kredi riski modelleri geliřtirilebileceęi dřnlmektedir. Teknolojiden faydalanarak srelerini daha iyi ynetebilen firmalar ciddi avantaj saęlayacak ve kriz dnemleri dahil belirsizlik ortamlarında daha srdrlebilir olacaklardır.



KAYNAKÇA

- Abbadi, S. M., & Karsh, S. M. A. (2013). Methods of evaluating credit risk used by commercial banks in Palestine. *International Research Journal of Finance and Economics*, 111(1), 146-159.
- Abdel-Aty, M., & Abdelwahab, H. (2004). Modeling rear-end collisions including the role of driver's visibility and light truck vehicles using a nested logit structure. *Accident Analysis & Prevention*, 36(3), 447-456. [https://doi.org/10.1016/s0001-4575\(03\)00040-x](https://doi.org/10.1016/s0001-4575(03)00040-x)
- Abdou, H. A., & Pointon, J. (2011). Credit scoring, statistical techniques and evaluation criteria: A review of the literature. *Intelligent Systems in Accounting, Finance and Management*, 18(2-3), 59-88. <https://doi.org/10.1002/isaf.325>
- Abdulla, Y., Dang, V. A., & Khurshed, A. (2017). Stock market listing and the use of trade credit: Evidence from public and private firms. *Journal of Corporate Finance*, 46(C), 391-410. <https://doi.org/10.1016/j.jcorpfin.2017.08.004>
- Adamko, P., Klieštík, T., & Birtus, M. (2014). History of credit risk models. In G. Lee (Ed.), *2nd International Conference on Economics and Social Science (ICESS 2014)* (Vols. 61-62, pp. 148-153). Information Engineering Research Institute, Advances in Education Research.
- Addo, P., Guegan, D., & Hassani, B. (2018). Credit risk analysis using machine and deep learning models. *Risks*, 6(2), 38. <https://doi.org/10.3390/risks6020038>
- Ağca, Ş., Birge, J. R., Wang, Z., & Wu, J. (2023). The impact of COVID-19 on supply chain credit risk. *Production and Operations Management*, 32(12), 4088-4113. <https://doi.org/10.1111/poms.14079>
- Akar, Ö., & Güngör, O. (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Journal of Geodesy and Geoinformation*, 1(2), 139-146. <https://doi.org/10.9733/jgg.241212.1t>
- Akpınar, N. (2019). *Makine öğrenmesi teknikleriyle kredi başvuru skor kartının oluşturulması* [Yayınlanmamış Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi.
- Aktaş, R., Doğanay, M. M., & Yıldız, B. (2003). Mali başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması. *Ankara Üniversitesi SBF Dergisi*, 58(4), 1-24. https://doi.org/10.1501/sbfder_0000001691
- Al-Hadi, A., & Al-Abri, A. (2021). Firm-Level trade credit responses to covid-19-induced monetary and fiscal policies: International evidence. *Research in International Business and Finance*, 60(101568), 101568. <https://doi.org/10.1016/j.ribaf.2021.101568>
- Al Mazrouei, F., & Nobanee, H. (2020). Machine learning in finance: A mini-review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3539038>
- Alagöz, G., & Çanakoglu, E. (2021). Credit risk analysis using machine learning algorithms. *2021 29th Signal Processing and Communications Applications Conference (SIU)*, 1-4.

<https://doi.org/10.1109/SIU53274.2021.9477873>

- Allianz. (2023). *Ülke risk derecelendirmeleri 2023 2.Ç.* [Map]. Allianz Trade. https://www.allianz-trade.com/content/dam/onemarketing/aztrade/allianz-trade_com/tr_TR/main/methodologies/Allianz_Trade_Ulke_Risk_Haritasi.pdf
- Altan, G. (2022). *Türk bankacılık sisteminde UFRS çerçevesinde firmaların derecelendirilmesi ve makine öğrenmesi ile model önerisi* [Yayınlanmamış Doktora Tezi]. Marmara Üniversitesi.
- Altınay, A., & Akıncı, Ö. S. (2018). Antik dönemden Bretton Woods’a finansal düzenlemelerin yolculuğu. *Finans Politik ve Ekonomik Yorumlar Dergisi*, 55(643), 25–46.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609.
- Altman, E. I. (2005). An emerging market credit scoring system for corporate bonds. *Emerging Markets Review*, 6(4), 311–323. <https://doi.org/10.1016/j.ememar.2005.09.007>
- Altman, E. I., & Hotchkiss, E. (2005). *Corporate financial distress and bankruptcy*. John Wiley & Sons, Inc. <https://doi.org/10.1002/9781118267806>
- Altman, E. I., Marco, G., & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (The Italian experience). *Journal of Banking & Finance*, 18(3), 505–529. [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8)
- Altman, E. I., & Sabato, G. (2007). Modelling credit risk for SMEs: Evidence from the U.S. Market. *Abacus*, 43(3), 332–357. <https://doi.org/10.1111/j.1467-6281.2007.00234.x>
- Altman, E. I., & Saunders, A. (1997). Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*, 21(11-12), 1721–1742. [https://doi.org/10.1016/s0378-4266\(97\)00036-8](https://doi.org/10.1016/s0378-4266(97)00036-8)
- Amat, O., Manini, R., & Antón Renart, M. (2017). Credit concession through credit scoring: Analysis and application proposal. *Intangible Capital*, 13(1), 51–70. <https://doi.org/10.3926/ic.903>
- Amazon Web Services, Inc. (b.t.). *Makine öğrenimi nedir? Yeni başlayanlar için kurumsal makine öğrenimi kılavuzu- AWS*. Amazon Web Services, Inc. <https://aws.amazon.com/tr/what-is/machine-learning/>
- Angelini, E., di Tollo, G., & Roli, A. (2008). A neural network approach for credit risk evaluation. *The Quarterly Review of Economics and Finance*, 48(4), 733–755. <https://doi.org/10.1016/j.qref.2007.04.001>
- Anguita, D., Ghio, A., Greco, N., Oneto, L., & Ridella, S. (2010, July 1). *Model selection for support vector machines: Advantages and disadvantages of the machine learning theory*. IEEE Xplore; IEEE. <https://doi.org/10.1109/IJCNN.2010.5596450>
- Argüello-Prada, E. J., & Valencia, R. D. M. (2023). On the use of indexes derived from photoplethysmographic (PPG) signals for postoperative pain assessment: A narrative

- review. *Biomedical Signal Processing and Control*, 80, Part 1(104335). <https://doi.org/10.1016/j.bspc.2022.104335>
- Armeliu, H., Belfrage, C.-J., & Stenbacka, H. (2014). The mystery of the missing world trade growth after the global financial crisis. *Sveriges Riksbank Economic Review*, 2014(3), 7–22.
- Atiya, A. F. (2001). Bankruptcy prediction for credit risk using neural networks: A survey and new results. *IEEE Transactions on Neural Networks*, 12(4), 929–935. <https://doi.org/10.1109/72.935101>
- Auria, L., & Moro, R. A. (2008). Support vector machines (SVM) as a technique for solvency analysis. *DIW Berlin, German Institute for Economic Research, DIW Berlin Discussion Paper No. 811*. <https://doi.org/10.2139/ssrn.1424949>
- Ayyagari, M., Demirgüç-Kunt, A., & Maksimovic, V. (2010). Formal versus informal finance: Evidence from China. *Review of Financial Studies*, 23(8), 3048–3097. <https://doi.org/10.1093/rfs/hhq030>
- Aziz, S., Dowling, M., Hammami, H., & Piepenbrink, A. (2022). Machine learning in finance: A topic modeling approach. *European Financial Management*, 28(3), 744–770. <https://doi.org/10.1111/eufm.12326>
- Baesens, B., Van Gestel, T., Viaene, S., Stepanova, M., Suykens, J., & Vanthienen, J. (2003). Benchmarking state-of-the-art classification algorithms for credit scoring. *Journal of the Operational Research Society*, 54(6), 627–635. <https://doi.org/10.1057/palgrave.jors.2601545>
- Bahillo, J. A., Ganguly, S., Kremer, A., & Kristensen, I. (2016, July 21). *The value in digitally transforming credit risk management*. McKinsey&Company, Risk and Resilience. <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/the-value-in-digitally-transforming-credit-risk-management>
- Baker, S. R., Bloom, N., Davis, S. J., & Terry, S. J. (2020). *COVID-Induced economic uncertainty* (No. 26983). National Bureau of Economic Research. <https://doi.org/10.3386/w26983>
- Balcaen, S., & Ooghe, H. (2006). 35 years of studies on business failure: An overview of the classic statistical methodologies and their related problems. *The British Accounting Review*, 38(1), 63–93. <https://doi.org/10.1016/j.bar.2005.09.001>
- Ball, L., & Mankiw, N. G. (1995). Relative-Price changes as aggregate supply shocks. *The Quarterly Journal of Economics*, 110(1), 161–193. <https://doi.org/10.2307/2118514>
- Balyuk, T. (2023). FinTech lending and bank credit access for consumers. *Management Science*, 69(1), 555–575. <https://doi.org/10.1287/mnsc.2022.4319>
- Bao, W., Lianju, N., & Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems with Applications*, 128(C), 301–315. <https://doi.org/10.1016/j.eswa.2019.02.033>

- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83(C), 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>
- Bartosik, A., & Whittingham, H. (2021). *The era of artificial intelligence, machine learning, and data science in the pharmaceutical industry* (S. K. Ashenden, Ed.; pp. 119–137). Academic Press. <https://doi.org/10.1016/c2019-0-01262-9>
- Basel Committee on Banking Supervision. (2004). *International convergence of capital measurement and capital standards: A revised framework*. Bank for International Settlements.
- Bastos, R., & Pindado, J. (2013). Trade credit during a financial crisis: A panel data analysis. *Journal of Business Research*, 66(5), 614–620. <https://doi.org/10.1016/j.jbusres.2012.03.015>
- Batten, J. A., Bilgin, M. H., Demir, E., & Gozgor, G. (2023). Does globalization affect credit market controls? *International Review of Economics & Finance*, 85(2023), 21–43. Elsevier. <https://doi.org/10.1016/j.iref.2022.11.012>
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4(3), 71–111. <https://doi.org/10.2307/2490171>
- Becerra, O., Cavallo, E., & Scartascini, C. (2012). The politics of financial development: The role of interest groups and government capabilities. *Journal of Banking & Finance*, 36(3), 626–643. <https://doi.org/10.1016/j.jbankfin.2011.10.017>
- Beck, T. (2002). Financial development and international trade. *Journal of International Economics*, 57(1), 107–131. [https://doi.org/10.1016/s0022-1996\(01\)00131-3](https://doi.org/10.1016/s0022-1996(01)00131-3)
- Bekkers, E., Corong, E. L., Métivier, J., & Orlov, D. (2023). How will global trade patterns evolve in the long run? *World Trade Organization (WTO) Working Papers, ERSD-2023-03*. <https://doi.org/10.30875/25189808-2023-3>
- Bellotti, T., & Crook, J. (2009). Support vector machines for credit scoring and discovery of significant features. *Expert Systems with Applications*, 36(2), 3302–3308. <https://doi.org/10.1016/j.eswa.2008.01.005>
- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review, an International Science and Engineering Journal*, 54(3), 1937–1967. Springer. <https://doi.org/10.1007/s10462-020-09896-5>
- Berghoff, H. (2009). Civilizing capitalism? The beginnings of credit rating in the United States and Germany. *Bulletin of the GHI Washington, Fall 2009*(45), 9–28.
- Bertrand, J., & Murro, P. (2022). Firm–bank “odd couples” and trade credit: Evidence from Italian small- and medium-sized enterprises. *Economic Modelling*, 111(June 2022), 105829. <https://doi.org/10.1016/j.econmod.2022.105829>
- Beşe, E. (2007). *Finansal sistem stres testi uygulamaları ve Türkiye örneği* [Uzmanlık

- Yeterlilik Tezi]. <https://www3.tcmb.gov.tr/kutuphane/TURKCE/tezler/evrimbese.pdf>
- Bhatore, S., Mohan, L., & Reddy, Y. R. (2020). Machine learning techniques for credit risk evaluation: A systematic literature review. *Journal of Banking and Financial Technology*, 4(1), 111–138. <https://doi.org/10.1007/s42786-020-00020-3>
- Biais, B., & Gollier, C. (1997). Trade credit and credit rationing. *Review of Financial Studies*, 10(4), 903–937. <https://doi.org/10.1093/rfs/10.4.903>
- Białek-Jaworska, A., & Nehrebecka, N. (2016). The role of trade credit in business operations. *Argumenta Oeconomica*, 2(37), 189–231. <https://doi.org/10.15611/aoe.2016.2.08>
- Bielecki, T. R., & Rutkowski, M. (2004). Credit risk: Modeling, valuation and hedging. In *Springer Finance*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-04821-4>
- Bierman, H., & Hausman, W. H. (1970). The credit granting decision. *Management Science*, 16(8), B-519-B-532. <https://doi.org/10.1287/mnsc.16.8.b519>
- Bilginci, M. R., Kaya, G. O., & Türkyılmaz, A. (2019). Decision support system for credit risk management: An empirical study. *International Journal of Information Systems in the Service Sector (IJISSS)*, 11(2), 18–31. <https://doi.org/10.4018/IJISSS.2019040102>
- Boissay, F., Patel, N., & Shin, H. S. (2020). Trade credit, trade finance, and the COVID-19 crisis. *BIS Bulletin*, 24. <https://doi.org/10.2139/ssrn.3761890>
- Bolton, C. (2009). *Logistic regression and its application in credit scoring* [Master's Thesis, University of Pretoria]. SSRN Electronic Journal. <http://dx.doi.org/10.2139/ssrn.3761890>
- Boyes, W. J., Hoffman, D. L., & Low, S. A. (1989). An econometric analysis of the bank credit scoring problem. *Journal of Econometrics*, 40(1), 3–14. [https://doi.org/10.1016/0304-4076\(89\)90026-2](https://doi.org/10.1016/0304-4076(89)90026-2)
- Bozkurt, B. (2011). *Kredi ve Yurtlar Kurumunda kalan öğrencilerin memnuniyet derecelerinin lojistik regresyon yöntemi ile araştırılması: Edirne ili örneği* [Yayınlanmamış Yüksek Lisans Tezi]. T.C. Trakya Üniversitesi.
- Brasch, J. J. (1972). The role of trade credit in economic development. *Nebraska Journal of Economics and Business*, 11(1), 63–67. JSTOR. <http://www.jstor.org/stable/40472410>
- Brown, A. (2004). The origins and evolution of credit risk management. *GARP Review*, September/October 04(20), 32–34. Global Association of Risk Professionals.
- Brown, I., & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications*, 39(3), 3446–3453. <https://doi.org/10.1016/j.eswa.2011.09.033>
- Brown, K., & Moles, P. (2011). *Credit risk management* (2nd ed.). Edinburgh Business School, Heriot-Watt University. (Original work published 2008)
- Bruni, M. E., Beraldi, P., & Iazzolino, G. (2014). Lending decisions under uncertainty: A DEA approach. *International Journal of Production Research*, 52(3), 766–775. <https://doi.org/10.1080/00207543.2013.837985>

- Buera, F. J., Fattal Jaef, R. N., & Shin, Y. (2015). Anatomy of a credit crunch: From capital to labor markets. *Review of Economic Dynamics*, 18(1), 101–117. <https://doi.org/10.1016/j.red.2014.11.001>
- Bulut, H. (2019). *Basel III uzlaşısı ve Türk bankacılık sektörü üzerine etkileri* [Yayınlanmamış Dönem Projesi]. Pamukkale Üniversitesi. <https://hdl.handle.net/11499/3138>.
- Bumacov, V., Ashta, A., & Singh, P. (2017). Credit scoring: A historic recurrence in microfinance. *Strategic Change*, 26(6), 543–554. <https://doi.org/10.1002/jsc.2165>
- Bunyaminu, A., & Issah, M. (2012). Predicting corporate failure of UK's listed companies: Comparing multiple discriminant analysis and logistic regression. *International Research Journal of Finance and Economics*, 94(2012), 6–22.
- Burkart, M., & Ellingsen, T. (2004). In-Kind finance: A theory of trade credit. *American Economic Review*, 94(3), 569–590. <https://doi.org/10.1257/0002828041464579>
- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable machine learning in credit risk management. *Computational Economics*, 57(1), 203–216. <https://doi.org/10.1007/s10614020100420>
- Büyükbaşaran, T., Can, G. K., & Küçük, H. (2022). Macroeconomic effects of bank lending in an emerging economy: Evidence from Turkey. *Economic Modelling*, 115(C), 105946. <https://doi.org/10.1016/j.econmod.2022.105946>
- Camizuli, E., & Carranza, E. J. (2018). Exploratory Data Analysis (EDA). In S. L. L. Varela (Ed.), *The Encyclopedia of Archaeological Sciences* (pp. 1–7). John Wiley & Sons, Inc. <https://doi.org/10.1002/9781119188230.saseas0271>
- Cangül, O. (2006). *Diskriminant analizi ve bir uygulama denemesi* [Yayınlanmamış Yüksek Lisans Tezi]. Uludağ Üniversitesi.
- Caouette, J. B., Altman, E. I., & Narayanan, P. (1998). *Managing credit risk: The next great financial challenge* (1st ed.). John Wiley & Sons Inc.
- Caouette, J. B., Altman, E. I., Narayanan, P., & Nimmo, R. (2011). *Managing credit risk: The great challenge for global financial markets* (2nd ed.). John Wiley & Sons Inc.
- Carling, K., Jacobson, T., Jesper Lindé, & Kasper Roszbach. (2002). *Capital charges under Basel II: Corporate credit risk modelling and the macro economy* (No. 142). Sveriges Riksbank. <https://hdl.handle.net/10419/82450>
- Carruthers, B. G. (2013). From uncertainty toward risk: The case of credit ratings. *Socio-Economic Review*, 11(3), 525–551. <https://doi.org/10.1093/ser/mws027>
- Čermáková, J. (2020). *The future of credit scoring modelling using advanced techniques* [Unpublished Master's Thesis]. Charles University.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification : Applications, challenges and trends. *Neurocomputing*, 408(1), 189–215.

<https://doi.org/10.1016/j.neucom.2019.10.118>

- Chang, Y., Chang, K., & Wu, G. (2018). Application of extreme gradient boosting trees in the construction of credit risk assessment models for financial institutions. *Applied Soft Computing*, 73(December 2018), 914–920. <https://doi.org/10.1016/j.asoc.2018.09.029>
- Chen, C., & Kieschnick, R. (2018). Bank credit and corporate working capital management. *Journal of Corporate Finance*, 48(February 2018), 579–596. <https://doi.org/10.1016/j.jcorpfin.2017.12.013>
- Chen, D., Liu, M., Ma, T., & Martin, X. (2017). Accounting quality and trade credit. *Accounting Horizons*, 31(3), 69–83. <https://doi.org/10.2308/acch-51711>
- Chen, N., Ribeiro, B., & Chen, A. (2016). Financial credit risk assessment: A recent review. *Artificial Intelligence Review*, 45(1), 1–23. <https://doi.org/10.1007/s10462-015-9434-x>
- Chen, S., Ma, H., & Wu, Q. (2019). Bank credit and trade credit: Evidence from natural experiments. *Journal of Banking & Finance*, 108(11), 105616. <https://doi.org/10.1016/j.jbankfin.2019.105616>
- Chen, T., & Guestrin, C. (2016). XGBoost: a Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*, 48, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, Y., Zeng, Y., Zheng, M., & He, Q.-C. (2024). Trade credit provision under uniform price regulation. *Omega*, 125(3), 103023. <https://doi.org/10.1016/j.omega.2023.103023>
- Chi, Q., & Li, W. (2017). Economic policy uncertainty, credit risks and banks' lending decisions: Evidence from Chinese commercial banks. *China Journal of Accounting Research*, 10(1), 33–50. <https://doi.org/10.1016/j.cjar.2016.12.001>
- Chod, J., Lyandres, E., & Yang, S. A. (2019). Trade credit and supplier competition. *Journal of Financial Economics*, 131(2), 484–505. <https://doi.org/10.1016/j.jfineco.2018.08.008>
- Choi, S.-Y. (2022). Credit risk interdependence in global financial markets: Evidence from three regions using multiple and partial wavelet approaches. *Journal of International Financial Markets, Institutions and Money*, 80(C), 101636. <https://doi.org/10.1016/j.intfin.2022.101636>
- Clarke, D. G., & McDonald, J. B. (1992). Generalized bankruptcy models applied to predicting consumer credit behavior. *Journal of Economics and Business*, 44(1), 47–62. <https://api.semanticscholar.org/CorpusID:154010921>
- Cohen, B., & Carruthers, B. G. (2014). The risk of rating. *Sociétés Contemporaines*, 93(1), 39–66. <https://doi.org/10.3917/soco.093.0039>
- Colquitt, J. (2007). *Credit risk management: How to avoid lending disasters and maximize earnings*. McGraw Hill Professional.
- Constantinescu, C., Mattoo, A., & Ruta, M. (2020). The global trade slowdown: Cyclical or structural? *The World Bank Economic Review*, 34(1), 121–142. <https://doi.org/10.1093/wber/lhx027>

- Coulibaly, B., Saprizza, H., & Zlate, A. (2013). Financial frictions, trade credit, and the 2008–09 global financial crisis. *International Review of Economics & Finance*, 26(April 2013), 25–38. <https://doi.org/10.1016/j.iref.2012.08.006>
- Crouhy, M., Galai, D., & Mark, R. (2000). A comparative analysis of current credit risk models. *Journal of Banking & Finance*, 24(1-2), 59–117. [https://doi.org/10.1016/s0378-4266\(99\)00053-9](https://doi.org/10.1016/s0378-4266(99)00053-9)
- Coşer, A., MaerR-Matei, M. M., & Albu, C. (2019). Predictive models for loan default risk assessment. *Economic Computation and Economic Cybernetics Studies and Research*, 53(2), 149–165. <https://doi.org/10.24818/18423264/53.2.19.09>
- Çallı, B. A., & Coşkun, E. (2021). A longitudinal systematic review of credit risk assessment and credit default predictors. *SAGE Open*, 11(4), 215824402110613. <https://doi.org/10.1177/21582440211061333>
- Çinko, M. (2006). Kredi kartı değerlendirme tekniklerinin karşılaştırılması. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 5(9), 143–153.
- Danenas, P., & Garsva, G. (2009). Support vector machines and their application in credit risk evaluation process. *Transformations in Business and Economics*, 8(3), 46–58.
- Danenas, P., & Garsva, G. (2015). Selection of support vector machines based classifiers for credit risk domain. *Expert Systems with Applications*, 42(6), 3194–3204. <https://doi.org/10.1016/j.eswa.2014.12.001>
- Danenas, P., Garsva, G., & Gudas, S. (2011). Credit risk evaluation model development using support vector based classifiers. *Procedia Computer Science*, 4(2011), 1699–1707. <https://doi.org/10.1016/j.procs.2011.04.184>
- Deakin, E. B. (1972). A discriminant analysis of predictors of business failure. *Journal of Accounting Research*, 10(1), 167–179. <https://doi.org/10.2307/2490225>
- Derspresso. (b.t.). *Minimum ve maksimum noktaları*. www.derspresso.com.tr. <https://www.derspresso.com.tr/matematik/turev/min-maks-nokta>
- Di Tommaso, C., Foglia, M., & Pacelli, V. (2023). The impact and the contagion effect of natural disasters on sovereign credit risk. An empirical investigation. *International Review of Financial Analysis*, 87(2023), 102578. <https://doi.org/10.1016/j.irfa.2023.102578>
- Dimitras, A. I., Zanakis, S. H., & Zopounidis, C. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal of Operational Research*, 90(3), 487–513. [https://doi.org/10.1016/03772217\(95\)000704](https://doi.org/10.1016/03772217(95)000704)
- Dixon, M. F., Halperin, I., & Bilokon, P. A. (2020). *Machine learning in finance: From theory to practice* (1st ed.). Springer Cham.
- Doğan, S., Büyükkör, Y., & Atan, M. (2022). A comparative study of corporate credit ratings prediction with machine learning. *Operations Research and Decisions*, 32(1), 25–47. <https://doi.org/10.37190/ord220102>
- Dornel, A., Engel, J., & Malouche, M. (2023, February 8). *Greasing the wheels of commerce*

- Trade finance and credit*. World Bank Blogs. The Trade Post; The World Bank Group. <https://blogs.worldbank.org/en/trade/greasing-wheels-commerce-trade-finance-and-credit>
- Doumpos, M., Kosmidou, K., Baourakis, G., & Zopounidis, C. (2002). Credit risk assessment using a multicriteria hierarchical discrimination approach: A comparative analysis. *European Journal of Operational Research*, 138(2), 392–412. [https://doi.org/10.1016/s0377-2217\(01\)00254-5](https://doi.org/10.1016/s0377-2217(01)00254-5)
- Doumpos, M., Lemonakis, C., Niklis, D., & Zopounidis, C. (2019). Analytical techniques in the assessment of credit risk. In *EURO advanced tutorials on operational research*. Springer Cham. <https://doi.org/10.1007/978-3-319-99411-6>
- Doumpos, M., & Zopounidis, C. (1999). A multicriteria discrimination method for the prediction of financial distress: The case of Greece. *Multinational Finance Journal*, 3(2), 71–101.
- Duman, E., Aktas, M. S., & Yahsi, E. (2023). Credit risk prediction based on psychometric data. *Computers*, 12(12), 248. <https://doi.org/10.3390/computers12120248>
- Duman, S., & Yılmaz Türkmen, S. (2023). Bankacılık sektöründe kredi risk yönetimi ve bir tahmin modeli örneği. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 15(28), 1–14. <https://doi.org/10.14784/marufacd.1252307>
- Dumitrescu, E., Hué, S., Hurlin, C., & Tokpavi, S. (2022). Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. *European Journal of Operational Research*, 297(3). <https://doi.org/10.1016/j.ejor.2021.06.053>
- Durand, D. (1941). *Risk elements in consumer instalment financing* (pp. 189–201). National Bureau of Economic Research. <https://econpapers.repec.org/RePEc:nbr:nberbk:dura41-1>
- Eke, S., & Toprak, O. (2020). Designing credit risk management process in companies. *Pressacademia*, 7(4), 392–404. <https://doi.org/10.17261/pressacademia.2020.1330>
- Engelmann, B., Hayden, E., & Tasche, D. (2003). Testing Rating Accuracy. *Risk*, 16(1), 82–86.
- Escalante, H. J. (2005). A comparison of outlier detection algorithms for machine learning. *Proceedings of the International Conference on Communications in Computing*, 228–237.
- Escobar, J. L. (n.d.). *Why machine learning (ML) is so popular in the 21st century*. Gamco. Retrieved April 22, 2024, from <https://gamco.es/en/automatic-popular-popular-learning-xxi-century/>
- Eser, G. (2021). *Tahmin problemleri için regresyon ağacı ve komşuluk tabanlı yöntemler geliştirilmesi: Kalıpcılık sektöründe bir uygulama* [Yayınlanmamış Yüksek Lisans Tezi]. Bursa Uludağ Üniversitesi.
- European Systemic Risk Board - ESRB. (2004). *Standard 4.4a Management of credit risk* (J. No. 1/120/2004). The Financial Supervision Authority. https://www.esrb.europa.eu/mppa/cbmd/shared/pdf/Finland/2013-12-11_4_4a_std11.pdf?c124601963cc460a86b7f5052055c711

- Fantazzini, D., & Figini, S. (2009). Random survival forests models for SME credit risk measurement. *Methodology and Computing in Applied Probability*, 11(1), 29–45. <https://doi.org/10.1007/s1100900890782>
- Feng, W., Zhao, Y. & Deng, J. (2009). Application of SVM based on principal component analysis to credit risk assessment in commercial banks. *2009 WRI Global Congress on Intelligent Systems*, 4, 49–52. <https://doi.org/10.1109/GCIS.2009.46>
- Ferrando, A., & Mulier, K. (2013). Do firms use the trade credit channel to manage growth? *Journal of Banking & Finance*, 37(8), 3035–3046. <https://doi.org/10.1016/j.jbankfin.2013.02.013>
- Fitzpatrick, A., & Lien, B. (2013). The use of trade credit by businesses. *Journal of Banking & Finance*, 37(8), 3035–3046.
- Fitzpatrick, P. J. (1932). A comparison of the ratios of successful industrial enterprises with those of failed companies. *Certified Public Accountant*, 12(July-December), 727–731.
- Furletti, M. J. (2002). An Overview and History of Credit Reporting. *Consumer Finance Institute Discussion Papers*, 02-07. *Federal Reserve Bank of Philadelphia*. <https://doi.org/10.2139/ssrn.927487>
- Galindo, J., & Tamayo, P. (2000). Credit risk assessment using statistical and machine learning: Basic methodology and risk modeling applications. *Computational Economics*, 15(1/2), 107–143. <https://doi.org/10.1023/a:1008699112516>
- Galitz, L. C. (1983). Consumer credit analysis. *Managerial Finance*, 9(3/4), 27–33. <https://doi.org/10.1108/eb013527>
- García, S., Ramírez-Gallego, S., Luengo, J., Benítez, José Manuel, & Herrera, F. (2016). Big data preprocessing: methods and prospects. *Big Data Analytics*, 1(1), 1–22. <https://doi.org/10.1186/s4104401600140>
- García-Teruel, P. J., & Martínez-Solano, P. (2010). Determinants of trade credit: A comparative study of European SMEs. *International Small Business Journal: Researching Entrepreneurship*, 28(3), 215–233. <https://doi.org/10.1177/0266242609360603>
- Gavrilaková, P., Valášková, K., & Dengov, V. (2014). Credit risk and its evaluation. *Advances in Education Research*, 61, 104–108.
- Gelpi, R.-M., & Julien-Labruyère, F. (2000). Usury in the ancient world. In M. L. Gavin (Trans.), *The History of Consumer Credit: Doctrines and Practices* (pp. 3–14). Palgrave Macmillan. https://doi.org/10.1057/9780230554511_1
- Ghasemzadeh, A., & Ahmed, M. M. (2019). Complementary parametric probit regression and nonparametric classification tree modeling approaches to analyze factors affecting severity of work zone weather-related crashes. *Journal of Modern Transportation*, 27(2), 129–140. <https://doi.org/10.1007/s4053401801786>
- Ghatasheh, N. (2014). Business Analytics using Random Forest Trees for Credit Risk Prediction: A Comparison Study. *International Journal of Advanced Science and*

- Technology*, 72(2014), 19–30. <https://doi.org/10.14257/ijast.2014.72.02>
- Gigliarano, C., Figini, S., & Muliere, P. (2014). Making classifier performance comparisons when ROC curves intersect. *Computational Statistics & Data Analysis*, 77(6869900), 300–312. <https://doi.org/10.1016/j.csda.2014.03.008>
- Gofman, M., & Wu, Y. (2022). Trade credit and profitability in production networks. *Journal of Financial Economics*, 143(1), 593–618. <https://doi.org/10.1016/j.jfineco.2021.05.054>
- Goh, R. Y., & Lee, L. S. (2019). Credit scoring: A review on support vector machines and metaheuristic approaches. *Advances in Operations Research*, 2019(March), 1–30. <https://doi.org/10.1155/2019/1974794>
- Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32(1), 100577. <https://doi.org/10.1016/j.jbef.2021.100577>
- Gourinchas, P. O. (2023, October 10). *Resilient global economy still limping along, with growing divergences*. International Monetary Fund; IMF Blog. <https://www.imf.org/en/Blogs/Articles/2023/10/10/resilient-global-economy-still-limping-along-with-growing-divergences>
- Goyal, S. K. (1985). Economic order quantity under conditions of permissible delay in payments. *The Journal of the Operational Research Society*, 36(4), 335–338. <https://doi.org/10.2307/2582421>
- Göktaş, A., Keskin, B., & Çakmakyapan, S. (2012). Lojistik Regresyon ve Doğrusal Diskriminant Analizlerinde Kullanılan Bazı İndekslerin Karşılaştırılması. *JSRTR*, 9(2), 54–64. <https://dergipark.org.tr/tr/download/articlefile/3552659>
- Grablowsky, B. J., & Talley, W. K. (1981). Probit and discriminant functions for classifying credit applicants: A comparison. *Journal of Economics & Business*, 33(3), 254–261.
- Greene, W. H. (1992). A statistical model for credit scoring. *NYU Working Paper No: 92-29*. <https://ssrn.com/abstract=1867088>
- Grennepois, N., Alvirescu, A. M., Bombail, M., & Bertholon-Lampiris, F. (2019). *Point of view: Using random forest for credit risk models*. Deloitte, Risk Advisory.
- Grimme, C., & Henzel, S. R. (2024). Uncertainty and credit conditions: Non-linear evidence from firm-level data. *International Review of Economics & Finance*, 93(PA), 1307–1323. <https://doi.org/10.1016/j.iref.2024.03.039>
- Gudivada, V. N., Irfan, M. T., Fathi, E., & Rao, D. L. (2016). Cognitive analytics: Going beyond big data analytics and machine learning. In *Cognitive Computing: Theory and Applications* (pp. 169–205). Elsevier.
- Gulcemal, T. (2021). Financial globalization, institutions and economic growth impact on financial sector development in fragile countries using GMM estimator. *Pressacademia*, 10(1), 36–46. <https://doi.org/10.17261/pressacademia.2021.1382>

- Guo, Y., He, J., Xu, L., & Liu, W. (2019). A novel multi-objective particle swarm optimization for comprehensible credit scoring. *Soft Computing*, 23(18), 9009–9023. <https://doi.org/10.1007/s00500-018-3509-y>
- Hahn, E., & Soyer, R. (2005). Probit and logit models: Differences in the multivariate realm. *The Journal of the Royal Statistical Society, Series B*(2005), 1–12.
- Hambly, B., Xu, R., & Yang, H. (2023). Recent advances in reinforcement learning in finance. *Mathematical Finance*, 33(3), 437–503. <https://doi.org/10.1111/mafi.12382>
- Hamerle, A., Liebig, T., & Roesch, D. (2003). *Benchmarking asset correlations*. Econometric Modeling: Capital Markets - Risk EJournal. <https://api.semanticscholar.org/CorpusID:15366569>
- Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: A review. *Journal of the Royal Statistical Society: Series a (Statistics in Society)*, 160(3), 523–541. <https://doi.org/10.1111/j.1467-985x.1997.00078.x>
- Hao, C., Alam, M., & Carling, K. (2010). Review of the literature on credit risk modeling: Development of the past 10 years. *Banks and Bank Systems*, 5(3), 43–60.
- Härdle, W., Moro, R., & Schäfer, D. (2005). Predicting bankruptcy with support vector machines. In *Statistical Tools for Finance and Insurance* (pp. 225–248). Springer Berlin. https://doi.org/10.1007/3-540-27395-6_10
- Härdle, W. K., Lee, Y.-J., Schhfer, D., & Yeh, Y.-R. (2007). *The default risk of firms examined with smooth support vector machines*. SFB 649 Discussion Paper, No. 2008,005. <https://doi.org/10.2139/ssrn.2894311>
- Hardy, W. E., & Adrian, J. L. (1985). A linear programming alternative to discriminant analysis in credit scoring. *Agribusiness*, 1(4), 285–292.
- Harris, T. (2015). Credit scoring using the clustered support vector machine. *Expert Systems with Applications*, 42(2), 741–750. <https://doi.org/10.1016/j.eswa.2014.08.029>
- Hasan, M. M., & Habib, A. (2019). Social capital and trade credit. *International Review of Financial Analysis*, 61(January 2019), 158–174. <https://doi.org/10.1016/j.irfa.2018.10.002>
- Hasan, R., & Ashfaq, M. (2021). Corruption and its diverse effect on credit risk: global evidence. *Future Business Journal*, 7(1), 18. <https://doi.org/10.1186/s43093021000601>
- Heffernan, S. (2005). *Modern banking*. John Wiley & Sons.
- Heinemann, F., & Tanz, B. (2008). The impact of trust on reforms. *Journal of Economic Policy Reform*, 11(3), 173–185. <https://doi.org/10.1080/17487870802405375>
- Helsel, D., & Hirsch, R. (2002). Statistical methods in water resources. In *Studies in Environmental Science* (First e-book, Vol. 49). United States Geological Survey.
- Henley, W. E., & Hand, D. J. (1997). Construction of a k-nearest neighbour credit scoring system. *IMA J Management Math*, 8(4), 305–321. <https://doi.org/10.1093/imaman/8.4.305>
- Herasymovych, M., Märka, K., & Lukason, O. (2019). Using reinforcement learning to

- optimize the acceptance threshold of a credit scoring model. *Applied Soft Computing*, 84, 105697. <https://doi.org/10.1016/j.asoc.2019.105697>
- Hiller, J. S., & Jones, L. S. (2022). Who's keeping score? : Oversight of changing consumer credit infrastructure. *American Business Law Journal*, 59(1), 61–121. <https://doi.org/10.1111/ablj.12199>
- Hodgson, G. (2006). Trade credit for crisis countries: The role of export credit agencies. In *Access to Trade Finance in Times of Crisis*. International Monetary Fund.
- Hu, L., Chen, J., Vaughan, J., Aramideh, S., Yang, H., Wang, K., Sudjianto, A., & Nair, V. N. (2021). Supervised machine learning techniques: An overview with applications to banking. *International Statistical Review*, 89(3), 573–604. <https://doi.org/10.1111/insr.12448>
- Huang, L., Ying, Q., Yang, S., & Hassan, H. (2019). Trade credit financing and sustainable growth of firms: Empirical evidence from China. *Sustainability*, 11(4), 1032. <https://doi.org/10.3390/su11041032>
- Huang, Y.-F., & Hsu, K.-H. (2008). An EOQ model under retailer partial trade credit policy in supply chain. *International Journal of Production Economics*, 112(2), 655–664. <https://doi.org/10.1016/j.ijpe.2007.05.014>
- Ibrahim, I., & Abdulazeez, A. (2021). The role of machine learning algorithms for diagnosing diseases. *Journal of Applied Science and Technology Trends*, 2(01), 10–19. <https://doi.org/10.38094/jastt20179>
- Ildız, E. (2009). *Eski Yunan ve Roma'da bankerlik* [Yayınlanmamış Yüksek Lisans Tezi]. İstanbul Üniversitesi.
- Imandoust, S. B., & Bolandraftar, M. (2013). Application of k-nearest neighbor (KNN) approach for predicting economic events: Theoretical background. *Journal of Engineering Research and Applications*, 3(5), 605–610.
- Ivanov, D., & Dolgui, A. (2020). Viability of intertwined supply networks: Extending the supply chain resilience angles towards survivability. A position paper motivated by COVID-19 outbreak. *International Journal of Production Research*, 58(10), 2904–2915. <https://doi.org/10.1080/00207543.2020.1750727>
- İldaş, T. (2021). Kredi riski ölçüm modellerinin değerlendirilmesi. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 13(25), 516–547. <https://doi.org/10.14784/marufacd.976580>
- Javier, F. (2017). Credit risk: Measurement. In *Financial Risk Management*. Palgrave Macmillan Cham. https://doi.org/10.1007/978-3-319-41366-2_9
- Jenkins, H., Alshareef, E., & Mohamad, A. (2023). The impact of corruption on commercial banks' credit risk: Evidence from a panel quantile regression. *International Journal of Finance & Economics*, 28(2), 1364–1375. <https://doi.org/10.1002/ijfe.2481>
- Jentzsch, N. (2007). Overview of credit reporting systems. In *An International Comparison of Credit Reporting Systems* (pp. 61–118). Springer. <https://doi.org/10.1007/978-3-540->

- Jiang, F., & Kim, K. A. (2015). Corporate governance in China: A modern perspective. *Journal of Corporate Finance*, 32(June 2015), 190–216.
- Jiang, H., Ching, W.-K., Yiu, K. F. C., & Qiu, Y. (2018). Stationary Mahalanobis kernel SVM for credit risk evaluation. *Applied Soft Computing*, 71(October 2018), 407–417. <https://doi.org/10.1016/j.asoc.2018.07.005>
- Jo, H., Han, I., & Lee, H. (1997). Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications*, 13(2), 97–108. [https://doi.org/10.1016/s0957-4174\(97\)00011-0](https://doi.org/10.1016/s0957-4174(97)00011-0)
- Johansson, Å., & Olaberria, E. (2014). Global trade and specialisation patterns over the next 50 years. *OECD Economic Policy Papers*, 10(July 2014). <https://doi.org/10.1787/5jz18gpwfxq4-en>
- Joseph, C. (2013). *Advanced credit risk analysis and management* (C. Joseph, Ed.). John Wiley & Sons. <https://doi.org/10.1002/9781118604878>
- Jun, Z. (2021). The development and application of support vector machine. *Journal of Physics: Conference Series*, 1748(5), 052006. <https://doi.org/10.1088/1742-6596/1748/5/052006>
- Kabir, M. N., Rahman, S., Rahman, M. A., & Anwar, M. (2021). Carbon emissions and default risk: International evidence from firm-level data. *Economic Modelling*, 103(C), 105617. <https://doi.org/10.1016/j.econmod.2021.105617>
- Kaczmarczyk, K., & Hernes, M. (2020). Financial decisions support using the supervised learning method based on random forests. *Procedia Computer Science*, 176(2020), 2802–2811. <https://doi.org/10.1016/j.procs.2020.09.276>
- Kadırgan, C., & Özlü, P. (2023). Financial crisis, global liquidity and trade credit channel: Evidence from Türkiye. *Emerging Markets Review*, 57(2023), 101073–101073. <https://doi.org/10.1016/j.ememar.2023.101073>
- Kalaycı, S. (2018). *Makine öğrenmesi yöntemleri ile kredi risk analizi* [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi]. https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=vDI5FFU37rX1z2HVV_KVfw&no=j2FMO4s_-aEnSJBK4VsmWg.
- Kalemli-Ozcan, S., Gourinchas, P.-O., Penciakova, V., & Sander, N. (2020). *COVID-19 and SME failures*. Working Paper No. 2020/207.
- Kamin, S. B., & Rogers, J. H. (2000). Output and the real exchange rate in developing countries: An application to Mexico. *Journal of Development Economics*, 61(1), 85–109. [https://doi.org/10.1016/s0304-3878\(99\)00062-0](https://doi.org/10.1016/s0304-3878(99)00062-0)
- Karaca, C. (2020). *Firmalarda ticari borç ve alacak yönetimi güncel yaklaşımlar ve analitik modeller*. Nobel Bilimsel Eserler.
- Karamizadeh, S., Abdullah, S. M., Halimi, M., Shayan, J., & Rajabi, M. Javad. (2014). Advantage and drawback of support vector machine functionality. *2014 International*

- Conference on Computer, Communications, and Control Technology (I4CT)*, 63–65.
<https://doi.org/10.1109/I4CT.2014.6914146>
- Karminsky, A. M., Grishunin, S., Dyachkova, N., & Bisenov, M. (2020). The comparison of empirical methods for modeling credit ratings of industrial companies from BRICS countries. *Eurasian Economic Review*, 10(2), 333–348.
<https://doi.org/10.1007/s40822019001304>
- Kavcıoğlu, Ş. (2011). Ticari bankacılıkta kredi riskinin ve kredi riski ölçüm modellerinin değerlendirilmesi. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 3(5), 11–20.
<https://dergipark.org.tr/tr/download/articlefile/3978>
- Kavcıoğlu, Ş. (2019). Kurumsal kredi skorlamasında klasik yöntemlerle yapay sinir ağı karşılaştırması. *Istanbul Journal of Economics / İstanbul İktisat Dergisi*, 69(2), 207–246.
<https://doi.org/10.26650/istjecon2019-0021>
- Kaya, R. (2008). *Bankaların kredi dönüşlerinin erken uyarı modeli ile incelenmesi* [Yayınlanmamış Yüksek Lisans Tezi]. Marmara Üniversitesi.
- Kealhofer, S. (2003). Quantifying credit risk I: Default prediction. *Financial Analysts Journal*, 59(1), 30–44. <https://doi.org/10.2469/faj.v59.n1.2501>
- Keenan, S. C., & Sobehart, J. R. (1999). *Performance measures for credit risk models*. Moody's Risk Management Services & Moody's Investors Service. Research Report # 1-10-10-99.
- Kelle, A. C., & Yüce, H. (2022). MQTT trafiğinde DoS saldırılarının makine öğrenmesi ile sınıflandırılması ve modelin SHAP ile yorumlanması. *Journal of Materials and Mechatronics: A*, 3(1), 50–62. <https://doi.org/10.55546/jmm.995091>
- Keskin, M. V. (2017, December 11). *İşte veri önümde, şimdi ne yapacağız?* VBO. <https://www.veribilimiokulu.com/iste-veri-onumde-simdi-ne-yapacagim/>
- Kırkıl, M. (2021). Ülke kredi riski derecelendirmede: İç ekonomik veriler ile temerrüt olasılığı ilişkisinin incelenmesi. *İktisat Politikası Araştırmaları Dergisi*, 8(1), 57–74.
<https://doi.org/10.26650/jep838626>
- Klapper, L., Laeven, L., & Rajan, R. (2012). Trade credit contracts. *Review of Financial Studies*, 25(3), 838–867. <https://doi.org/10.1093/rfs/hhr122>
- Klieštík, T., Kočišová, K., & Mišanková, M. (2015). Logit and probit model used for prediction of financial health of company. *Procedia Economics and Finance*, 23(2015), 850–855.
[https://doi.org/10.1016/s2212-5671\(15\)00485-2](https://doi.org/10.1016/s2212-5671(15)00485-2)
- Koçyiğit, S. Ç., & Demir, A. (2014). Türk bankacılık sektöründe kredi riski ve yönetimine ilişkin bir uygulama: Türkiye Garanti Bankası örneği. *İşletme Araştırmaları Dergisi*, 6(3), 222–246. TRDizin. <http://search/yayin/detay/253269>
- Koh, H. C. (1991). Model predictions and auditor assessments of going concern status. *Accounting and Business Research*, 21(84), 331–338.
<https://doi.org/10.1080/00014788.1991.9729848>
- Koklu, M., & Sabancı, K. (2016). Estimation of credit card customers payment status by using

- kNN and MLP. *International Journal of Intelligent Systems and Applications in Engineering*, 4(Special Issue1), 249–251. <https://doi.org/10.18201/ijisae.281901>
- Kong, J., Zhou, Y., Lai, H., Zhang, F., & Zhou, Z. (2016). Analysis of credit sale risk of emerging market product. *Procedia Computer Science*, 91(2016), 362–371. <https://doi.org/10.1016/j.procs.2016.07.097>
- Koulouridi, E., Kumar, S., Nario, L., Pepanides, T., & Vettori, M. (2020). *Managing and monitoring credit risk after the COVID-19 pandemic*. McKinsey & Company.
- Krzanowski, W. J., & Hand, D. J. (2009). *ROC curves for continuous data*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781439800225>
- Kulkarni, S. V., & Dhage, S. N. (2019). Advanced credit score calculation using social media and machine learning. *Journal of Intelligent & Fuzzy Systems*, 36(3), 2373–2380. <https://doi.org/10.3233/jifs-169948>
- Kumar, K., & Bhattacharya, S. (2006). Artificial neural network vs linear discriminant analysis in credit ratings forecast. *Review of Accounting and Finance*, 5(3), 216–227. <https://doi.org/10.1108/14757700610686426>
- Kumar, L. S., Pandimurugan, V., Usha, D., Guptha, M. N., & Hema, M. S. (2022). Random forest tree classification algorithm for predicating loan. *International Conference on Innovation and Application in Science and Technology*, 57(5), 2216–2222. <https://doi.org/10.1016/j.matpr.2021.12.322>
- Kumar, V. P., & Sowmya, I. (2021). A review on pros and cons of machine learning algorithms. *Journal of Engineering Sciences*, 12(10), 272–276.
- Kusrini, K., Luthfi, E. T., Muqorobin, M., & Abdullah, R. W. (2019). Comparison of Naive Bayes and K-NN method on tuition fee payment overdue prediction. *2019 4th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, 125–130. <https://doi.org/10.1109/icitisee48480.2019.9003782>
- Kwenda, F., & Holden, M. (2014). Trade credit in corporate financing in South Africa: Evidence from a dynamic panel data analysis. *Investment Management and Financial Innovations*, 11(4), 268–278.
- Lai, K. K., Yu, L., Zhou, L., & Wang, S. (2006). Credit risk evaluation with least square support vector machine. In *Rough Sets and Knowledge Technology, Machine Learning and KDD* (pp. 490–495.). Springer. https://doi.org/10.1007/11795131_71
- Lai, S., Chen, L., Wang, Q. S., & Anderson, H. (2022). Natural disasters, trade credit, and firm performance. *Economic Modelling*, 116(C), 106029. <https://doi.org/10.1016/j.econmod.2022.106029>
- Lando, D. (2009). Credit Risk Modeling. In T. Mikosch, J. Kreiß, R. A. Davis, & T. G. Andersen (Eds.), *Handbook of Financial Time Series* (pp. 787–798). Springer Berlin Heidelberg. https://doi.org/10.1007/9783540712978_35
- Lauer, J. (2022). Credit reporting and the history of commercial surveillance in America.

- Le Moigne, M. (2020). *Pandemic and trade: The dynamics of global trade in times of Corona* (No. 03-20). Kühne Center Impact Series. <https://doi.org/10.5167/uzh-256052>
- Lee, S., Ryu, J. H., & Kim, I. S. (2007). Landslide susceptibility analysis and its verification using likelihood ratio, logistic regression, and artificial neural network models: Case study of Youngin, Korea. *Landslides*, 4(4), 327–338. <https://doi.org/10.1007/s103460070088x>
- Lee, T. S., & Chen, I. F. (2005). A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines. *Expert Systems with Applications*, 28(4), 743–752. <https://doi.org/10.1016/j.eswa.2004.12.031>
- Lee, T. S., Chiu, C. C., Chou, Y. C., & Lu, C. J. (2006). Mining the customer credit using classification and regression tree and multivariate adaptive regression splines. *Computational Statistics & Data Analysis*, 50(4), 1113–1130. <https://doi.org/10.1016/j.csda.2004.11.006>
- Lee, T. S., Chiu, C. C., Lu, C. J., & Chen, I. F. (2002). Credit scoring using the hybrid neural discriminant technique. *Expert Systems with Applications*, 23(3), 245–254. [https://doi.org/10.1016/s0957-4174\(02\)00044-1](https://doi.org/10.1016/s0957-4174(02)00044-1)
- Lee, Y. (2007). Application of support vector machines to corporate credit rating prediction. *Expert Systems with Applications*, 33(1), 67–74. <https://doi.org/10.1016/j.eswa.2006.04.018>
- Lei, S. Q. (2014). Applied technology in business credit in the enterprise's short-term finance. *Advanced Materials Research*, 859, 422–425. <https://doi.org/10.4028/www.scientific.net/AMR.859.422>
- Lemercier, C., & Zalc, C. (2012). For a new approach to credit relations in modern history. *Annales (English Ed.)*, 67(4), 663–691. Cambridge Core. <https://doi.org/10.1017/S2398568200000418>
- Li, J., Liu, H., Yang, Z., & Han, L. (2021). A credit risk model with small sample data based on GXGBoost. *Applied Artificial Intelligence*, 35(15), 1550–1566. <https://doi.org/10.1080/08839514.2021.1987707>
- Li, X. L., & Zhong, Y. (2012). An overview of personal credit scoring: Techniques and future work. *International Journal of Intelligence Science*, 02(04), 181–189. <https://doi.org/10.4236/ijis.2012.224024>
- Li, Y. (2019). Credit Risk Prediction Based on Machine Learning Methods. *2019 14th International Conference on Computer Science & Education (ICCSE)*, 1011–1013. <https://doi.org/10.1109/ICCSE.2019.8845444>
- Li, Z., Zhang, J., Yao, X., & Kou, G. (2021). How to identify early defaults in online lending: A cost-sensitive multilayer learning framework. *Knowledge-Based Systems*, 221(June 2021), 106963. <https://doi.org/10.1016/j.knosys.2021.106963>

- Lin, M., & Chen, J. (2023). Research on credit big data algorithm based on logistic regression. *Procedia Computer Science*, 228(2023), 511–518. <https://doi.org/10.1016/j.procs.2023.11.058>
- Lin, S. (2003). China's government debt: How serious? *China: An International Journal*, 01(01), 73–98. <https://doi.org/10.1142/s0219747203000062>
- Liu, J., Zhang, S., & Fan, H. (2022). A two-stage hybrid credit risk prediction model based on XGBoost and graph-based deep neural network. *Expert Systems with Applications*, 195(1 June 2022), 116624. <https://doi.org/10.1016/j.eswa.2022.116624>
- Lo Duca, M., Moccero, D., & Parlapiano, F. (2024). The impact of macroeconomic and monetary policy shocks on credit risk in the Euro Area corporate sector. In *SSRN Electronic Journal*. ECB Working Paper No. 2024/2897. <https://doi.org/10.2139/ssrn.4711248>
- Long, M. S., Malitz, I. B., & Abraham, R. S. (1993). Trade Credit, Quality Guarantees, and Product Marketability. *Financial Management*, 22(4), 117–127. JSTOR. <https://doi.org/10.2307/3665582>
- Love, I., & Zaidi, R. (2010). Trade credit, bank credit and financial crisis. *International Review of Finance*, 10(1), 125–147. <https://doi.org/10.1111/j.1468-2443.2009.01100.x>
- Ma, H., & Guo, Y. (2010). Credit Risk Evaluation Based on Artificial Intelligence Technology. *2010 International Conference on Artificial Intelligence and Computational Intelligence*, 1, 200–203. <https://doi.org/10.1109/AICI.2010.48>
- Machokoto, M., Gyimah, D., & Ibrahim, B. M. (2022). The evolution of trade credit: new evidence from developed versus developing countries. *Review of Quantitative Finance and Accounting*, 59(3), 857–912. <https://doi.org/10.1007/s11156-022-01061-z>
- Mahalakshmi, K., & Sujatha, P. (2023). The role of exploratory data analysis and preprocessing in the machine learning predictive model for heart disease. *2023 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)*, 1–8. <https://doi.org/10.1109/ACCAI58221.2023.10199714>
- Mahesh, B. (2020). Machine learning algorithms - A review. *International Journal of Science and Research*, 9(1), 381–386.
- Manzo, G. (2013). Political uncertainty, credit risk premium and default risk [Doctoral dissertation, The University of Chicago Booth School of Business]. In *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2376608>
- Markov, A., Seleznyova, Z., & Lapshin, V. (2022). Credit scoring methods: Latest trends and points to consider. *The Journal of Finance and Data Science*, 8(A1-A2), 180–201. <https://doi.org/10.1016/j.jfds.2022.07.002>
- Martin, D. (1977). Early warning of bank failure: A logit regression approach. *Journal of Banking & Finance*, 1(3), 249–276. [https://doi.org/10.1016/03784266\(77\)90022X](https://doi.org/10.1016/03784266(77)90022X)
- McCorkell, P. L. (2002). The impact of credit scoring and automated underwriting on credit availability. In T. A. Durkin & M. E. Staten (Eds.), *The Impact of Public Policy on*

- Consumer Credit* (pp. 209–227). Springer US + Business Media, LLC. https://doi.org/10.1007/978-1-4615-1415-2_8
- McGuinness, G., Hogan, T., & Powell, R. (2018). European trade credit use and SME survival. *Journal of Corporate Finance*, 49, 81–103. <https://doi.org/10.1016/j.jcorpfin.2017.12.005>
- McKibbin, W. J., & Fernando, R. (2020). *Global macroeconomic scenarios of the COVID-19 pandemic*. CAMA Working Paper No. 62/2020. <https://doi.org/10.2139/ssrn.3635103>
- Merton, R. C. (1994). Influence of mathematical models in finance on practice: Past, present and future. *Philosophical Transactions of the Royal Society of London. Series A: Physical and Engineering Sciences*, 347(1684), 451–463. <https://doi.org/10.1098/rsta.1994.0055>
- Mian, S. L., & Smith, W. (1992). Accounts Receivable Management Policy: Theory and Evidence. *Journal of Finance*, 47(1), 169–200. <https://econpapers.repec.org/RePEc:bla:jfinan:v:47:y:1992:i:1:p:169200>
- Mihalovič, M. (2016). Performance comparison of multiple discriminant analysis and logit models in bankruptcy prediction. *Economics & Sociology*, 9(4), 101–118. <https://doi.org/10.14254/2071-789x.2016/9-4/6>
- Milo, T., & Somech, A. (2020). Automating exploratory data analysis via machine learning: An overview. *SIGMOD/PODS '20: International Conference on Management of Data*, 2617–2622. <https://doi.org/10.1145/3318464.3383126>
- Min, J. H., & Lee, Y. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications*, 28(4), 603–614. <https://doi.org/10.1016/j.eswa.2004.12.008>
- Mirza, A. (2006). *Kredi riski yönetiminde erken uyarı sistemleri ve sorunlu kredilerin izlenmesi* [Yayınlanmamış Yüksek Lisans Tezi]. Dokuz Eylül Üniversitesi.
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine learning algorithms and applications* (ebook). CRC Press. <https://doi.org/10.1201/9781315371658>
- Molina, C. A., & Preve, L. A. (2012). An empirical analysis of the effect of financial distress on trade credit. *Financial Management*, 41(1), 187–205. <https://doi.org/10.1111/j.1755-053x.2012.01182.x>
- Moreira, L., Dantas, C., Oliveira, L., Jorge, & Ogasawara, E. (2018). On evaluating data preprocessing methods for machine learning models for flight delays. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://api.semanticscholar.org/CorpusID:52985715>
- Mori, H., & Yasushi Umezawa. (2007). Credit risk evaluation in power market with random forest. *2007 IEEE International Conference on Systems, Man and Cybernetics*, 3737–3742. <https://doi.org/10.1109/ICSMC.2007.4413777>
- Moscatelli, M., Parlapiano, F., Narizzano, S., & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161(6), 113567. <https://doi.org/10.1016/j.eswa.2020.113567>

- Myers, S. C., & Majluf, N. S. (1984). Corporate financing and investment decisions when firms have information that investors do not have. *Journal of Financial Economics*, 13(2), 187–221. [https://doi.org/10.1016/0304-405X\(84\)90023-0](https://doi.org/10.1016/0304-405X(84)90023-0)
- Nacar, E. N., & Erdebilli, B. (2021). Makine öğrenmesi algoritmaları ile satış tahmini. *Endüstri Mühendisliği*, 32(2), 307–320. <https://doi.org/10.46465/endustrimuhendisligi.811183>
- Naili, M., & Lahrichi, Y. (2020). The determinants of banks' credit risk: Review of the literature and future research agenda. *International Journal of Finance & Economics*, 27(1). <https://doi.org/10.1002/ijfe.2156>
- Narzhanov, Y. (2011). *Comparative study of modern credit risk assessment methods* [Doctoral Dissertation, The British University in Dubai]. Semantic Scholar. <https://api.semanticscholar.org/CorpusID:56457821>
- Nayak, G. N., & Turvey, C. G. (1997). Credit risk assessment and the opportunity costs of loan misclassification. *Canadian Journal of Agricultural Economics/Revue Canadienne D'agroeconomie*, 45(3), 285–299. <https://doi.org/10.1111/j.1744-7976.1997.tb00209.x>
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *HORIZONS.B*, B(4), 51–62. <https://doi.org/10.20544/horizons.b.04.1.17.p05>
- Ng, C. K., Smith, J. K., & Smith, R. L. (1999). Evidence on the determinants of credit terms used in interfirm trade. *The Journal of Finance*, 54(3), 1109–1129. <https://doi.org/10.1111/0022-1082.00138>
- Njuguna, R., & Sowon, K. (2021). Poster: A scoping review of alternative credit scoring literature. *ACM COMPASS 2021*, 437–444. <https://doi.org/10.1145/3460112.3471972>
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://doi.org/10.2307/2490395>
- Okur, H. (2020). *Makine öğrenmesi yöntemleriyle kredi riski tahmini* [Yayınlanmamış Yüksek Lisans Tezi]. Gazi Üniversitesi.
- Omary, Z., & Mtenzi, F. (2010). Machine learning approach to identifying the dataset threshold for the performance estimators in. *International Journal for Infonomics*, 3(3), 314–325. <https://doi.org/10.20533/iji.1742.4712.2010.0034>
- OppU. (2023, July 27). *(unknown AI creator tool help). A brief history of credit scores* (T. Altman, Ed.). OppLoans. <https://www.opploans.com/oppu/building-credit/a-brief-history-of-credit-scores/>
- Oroy, K., & Evan, P. (2024). Machine learning applications in finance: Predictive analytics and risk management. *EasyChair Preprint*, no. 12239.
- Óskarsdóttir, M., Bravo, C., Sarraute, C., Vanthienen, J., & Baesens, B. (2019). The value of big data for credit scoring: Enhancing financial inclusion using mobile phone data and social network analytics. *Applied Soft Computing*, 74(January 2019), 26–39. <https://doi.org/10.1016/j.asoc.2018.10.004>
- Öztaş, M. (2022). *Diskriminant analizi ve CHAID'in karşılaştırılması üzerine bir araştırma*

[Yayınlanmamış Yüksek Lisans Tezi]. Akdeniz Üniversitesi.

- Pang, H., Lin, A., Holford, M., Enerson, B. E., Lu, B., Lawton, M. P., Floyd, E., & Zhao, H. (2006). Pathway analysis using random forests classification and regression. *Bioinformatics*, 22(16), 2028–2036. <https://doi.org/10.1093/bioinformatics/btl344>
- Patil, P. (2018, March 23). *What is exploratory data analysis?* Medium. <https://towardsdatascience.com/exploratory-data-analysis-8fc1cb20fd15>
- Paul, S. Y., Guermat, C., & Devi, S. (2018). Why do firms invest in accounts receivable? An empirical investigation of the Malaysian manufacturing sector. *Journal of Accounting in Emerging Economies*, 8(2), 166–184. <https://doi.org/10.1108/jaee-01-2017-0005>
- Paul, S., & Boden, R. (2014). *Trade credit: A literature review* (pp. 1–39). British Business Bank.
- Prado, J. W. do, Alcântara, V. de C., Carvalho, F. de M., Vieira, K. C., Machado, L. K. C., & Tonelli, D. F. (2016). Multivariate analysis of credit risk and bankruptcy research data: A bibliometric study involving different knowledge fields (1968–2014). *Scientometrics*, 106(3), 1007–1029. <https://doi.org/10.1007/s11192-015-1829-6>
- Ptak-Chmielewska, A. (2016). Statistical models for corporate credit risk assessment – rating models. *Acta Universitatis Lodzensis. Folia Oeconomica*, 3(322). <https://doi.org/10.18778/0208-6018.322.09>
- Qin, R. (2022). The construction of corporate financial management risk model based on XGBoost algorithm. *Journal of Mathematics*, 2022(1), 1–8. <https://doi.org/10.1155/2022/2043369>. Article ID: 043369.
- Rahman, A. (2019). Statistics-based data preprocessing methods and machine learning algorithms for big data analysis. *International Journal of Artificial Intelligence*, 17(2), 44–65. <https://researchoutput.csu.edu.au/en/publications/statistics-based-data-preprocessing-methods-and-machine-learning->
- Rajan, R. G., & Zingales, L. (1995). What Do We Know about Capital Structure? Some Evidence from International Data. *The Journal of Finance*, 50(5), 1421–1460.
- Rajan, R., & Zingales, L. (1998). Financial dependence and growth. *American Economic Review*, 88(3), 559–586. <https://doi.org/10.3386/w5758>
- Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. In *CoRR* (Vol. abs/1811.12808). <http://arxiv.org/abs/1811.12808>
- Reichert, A. K., Cho, C.-C., & Wagner, G. M. (1983). An examination of the conceptual issues involved in developing credit-scoring models. *Journal of Business & Economic Statistics*, 1, 101–114. <https://api.semanticscholar.org/CorpusID:154817023>
- Riad, N., Errico, L., Henn, C., Saborowski, C., Saito, M., & Jarkko Turunen. (2012). *Changing Patterns of Global Trade: Vol. Volume 2012: Issue 001*. International Monetary Fund. <https://doi.org/10.5089/9781616352073.087>
- Rosenberg, E., & Gleit, A. (1994). Quantitative Methods in Credit Management: A Survey.

- Operations Research*, 42(4), 589–613. JSTOR. <http://www.jstor.org/stable/171615>
- Roy, A. G., & Urolagin, S. (2019). Credit risk assessment using decision tree and support vector machine based data analytics. In M. Mateev & P. Poutziouris (Eds.), *Creative Business and Social Innovations for a Sustainable Future* (pp. 79–84). Springer Cham. https://doi.org/10.1007/978-3-030-01662-3_10
- Rötheli, T. (2013). Innovations in US Banking Practices and the Credit Boom of the 1920s. *Business History Review*, 87(2), 309–327. Cambridge Core. <https://doi.org/10.1017/S000768051300041X>
- Runchi, Z., Liguó, X., & Qin, W. (2023). An ensemble credit scoring model based on logistic regression with heterogeneous balancing and weighting effects. *Expert Systems with Applications*, 212(February 2023), 118732. <https://doi.org/10.1016/j.eswa.2022.118732>
- Sá, E., & Pereira, A. (2015). Credit risk measures – a case of renewable energy companies. *Copernican Journal of Finance & Accounting*, 4(1), 147–147. <https://doi.org/10.12775/cjfa.2015.010>
- Sabato, G. (2010). Credit risk scoring models. In *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1546347>
- Sakri, S. (2022). Assessment of deep neural network and gradient boosting machines for credit risk prediction accuracy. *2022 14th International Conference on Computational Intelligence and Communication Networks (CICN)*, 2022(1), 1–7. <https://doi.org/10.1109/cicn56167.2022.10008264>
- Salman, M. (2004). *Türkiye’de ödeyememe riskinin ölçülmesine ekonometrik bir yaklaşım* [Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi.
- Saputri, S. D., & Ermatita, E. (2019). Credit scoring kelayakan debitur menggunakan metode hybrid ANN backpropagation dan TOPSIS. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 3(1), 73–78. <https://doi.org/10.29207/resti.v3i1.847>
- Saravanan, R., & Sujatha, P. (2018). A state of art techniques on machine learning algorithms: A perspective of supervised learning approaches in data classification. *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, 945–949. <https://doi.org/10.1109/ICCONS.2018.8663155>
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3), 1–21. Springer. <https://doi.org/10.1007/s42979-021-00592-x>
- Sarker, I. H., Kayes, Badsha, S., Alqahtani, H., Watters, P., & Ng, A. (2020). Cybersecurity data science: an overview from machine learning perspective. *Journal of Big Data*, 7(1), 41. <https://doi.org/10.1186/s40537020003185>
- Saunders, A., & Allen, L. (2002). Credit risk measurement: New approaches to value at risk and other paradigms. In *Wiley.com* (2nd ed.). John Wiley & Sons, Inc. Wiley Finance. <https://www.wiley.com/en-gb/Credit+Risk+Measurement%3A+New+Approaches+to+Value+at+Risk+and+Other+P>

- aradigms%2C+2nd+Edition-p-9780471274766
- Schober, P., Boer, C., & Schwarte, L. A. (2018). Correlation coefficients: Appropriate Use and Interpretation. *Anesthesia & Analgesia*, 126(5), 1763–1768. <https://doi.org/10.1213/ane.00000000000002864>
- Schwartz, R. A. (1974). An Economic Model of Trade Credit. *Journal of Financial and Quantitative Analysis*, 9(4), 643–657. Cambridge Core. <https://doi.org/10.2307/2329765>
- Seifert, D., Seifert, R. W., & Protopappa-Sieke, M. (2013). A review of trade credit literature: Opportunities for research in operations. *European Journal of Operational Research*, 231(2), 245–256. <https://doi.org/10.1016/j.ejor.2013.03.016>
- Sharma, D. K., Chatterjee, M., Kaur, G., & Vavilala, S. (2022). Deep learning applications for disease diagnosis. In D. Gupta, U. Kose, A. Khanna, & V. E. Balas (Eds.), *Deep Learning for Medical Applications with Unique Data* (pp. 31–51). Academic Press. <https://doi.org/10.1016/b978-0-12-824145-5.00005-8>
- Shi, S., Tse, R., Luo, W., D’Addona, S., & Pau, G. (2022). Machine learning-driven credit risk: A systemic review. *Neural Computing and Applications*, 34(17), 14327–14339. <https://doi.org/10.1007/s00521-022-07472-2>
- Shin, K.-S., Lee, T. S., & Kim, H. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(1), 127–135. <https://doi.org/10.1016/j.eswa.2004.08.009>
- Shipley, D., & Davies, L. (1991). The role and burden-allocation of credit in distribution channels. *Journal of Marketing Channels*, 1(1), 3–22. https://doi.org/10.1300/j049v01n01_02
- Shoumo, S. Z. H., Dhruba, M. I. M., Hossain, S., Ghani, N. H., Arif, H., & Islam, S. (2019). Application of machine learning in credit risk assessment: A prelude to smart banking. *TENCON 2019 IEEE Region 10 Conference (TENCON)*, 2023–2028. <https://doi.org/10.1109/TENCON.2019.8929527>
- Singh, K., & Upadhyaya, S. (2012). Outlier detection: Applications and techniques. *JCSI International, Journal of Computer Science Issues*, 9(1), 307–323. No:3.
- Smith, D. S. (2010). The Elimination of the Unworthy: Credit Men and Small Retailers in Progressive Era Capitalism. *The Journal of the Gilded Age and Progressive Era*, 9(2), 197–220. JSTOR. <http://www.jstor.org/stable/27821467>
- Smith, P. F. (1964). Measuring Risk on Consumer Instalment Credit. *Management Science*, 11(2), 327–340. JSTOR. <http://www.jstor.org/stable/2627605>
- Snaije, B. (2017). Can finance and credit enable economic growth and democracy? In G. Luciani (Ed.), *Combining Economic and Political Development: The Experience of MENA* (pp. 132–143). Brill; JSTOR. <http://www.jstor.org/stable/10.1163/j.ctt1w8h356.14>
- Somvanshi, M., Chavan, P., Tambade, S., & Shinde, S. V. (2016). A review of machine learning techniques using decision tree and support vector machine. *2016 International Conference*

- on Computing Communication Control and Automation (ICCUBEA), 1–7. <https://doi.org/10.1109/ICCUBEA.2016.7860040>
- Song, W., Min, J., & Yang, J. (2023). Credit risk assessment of heavy-polluting enterprises: A wide- ℓ_p penalty and deep learning approach. *Data-Driven Decision Making: Models, Methods and Applications, Mathematics*, 11(16), No 3462. <https://doi.org/10.3390/math11163462>
- Song, Y., Liang, J., Lu, J., & Zhao, X. (2017). An efficient instance selection algorithm for k nearest neighbor regression. *Neurocomputing*, 251(16 August 2017), 26–34. <https://doi.org/10.1016/j.neucom.2017.04.018>
- Spuchľakova, E., & Cug, J. (2015). Credit Risk and LGD Modelling. *Procedia Economics and Finance*, 23(2015), 439–444. [https://doi.org/10.1016/s2212-5671\(15\)00379-2](https://doi.org/10.1016/s2212-5671(15)00379-2)
- Stals, C. (1998, October 28). *Importance of credit extension for macroeconomic financial stability* [BIS Review 109/1998]. Institute of Credit Management Meeting. www.bis.org/review/r981109f.pdf
- Stella, O. (2019). Discriminant analysis: An analysis of its predictship function. *Journal of Education and Practice*, 10(5), 50–57. <https://doi.org/10.7176/jep/10-5-04>
- Subasi, A. (2020). *Practical machine learning for data analysis using Python*. Academic Press.
- Sueyoshi, T. (2006). DEA-Discriminant analysis: Methodological comparison among eight discriminant analysis approaches. *European Journal of Operational Research*, 169(1), 247–272. <https://doi.org/10.1016/j.ejor.2004.05.025>
- Summers, B., & Wilson, N. (2003). Trade credit and customer relationships. *Managerial and Decision Economics*, 24(6-7), 439–455. <https://doi.org/10.1002/mde.1041>
- Sun, G., Li, T., Su, J., & Shi, D. (2024). Digital economy, institutional environment, and the credit risks of commercial banks. *Emerging Markets Finance and Trade*, 60(4), 650–662. Taylor & Francis Online. <https://doi.org/10.1080/1540496x.2023.2250903>
- Sundaram, R. (2001). Multiple discriminant analysis. In *The Institute for Signal and Information Processing*. [course paper]. Mississippi State University. https://isip.piconepress.com/courses/msstate/ece_8443/papers/2001_spring/mmmda/p02_paper_v0.pdf
- Sutton, R. S., & Barto, A. (2018). *Reinforcement learning : An introduction*. The Mit Press.
- Sytnychenko, K. (2023). What to know before taking out a payday loan to improve your credit score. *International Science Journal of Management, Economics & Finance*, 2(2), 10–16. <https://doi.org/10.46299/j.isjmef.20230202.02>
- Tang, L., Cai, F., & Ouyang, Y. (2019). Applying a nonparametric random forest algorithm to assess the credit risk of the energy industry in China. *Technological Forecasting and Social Change*, 144(Complete), 563–572. <https://doi.org/10.1016/j.techfore.2018.03.007>
- Taş, C. (2023). *Comparison of machine learning and standard credit risk models' performances in credit risk scoring of buy now pay later customers* [Unpublished Master's

- Thesis]. <https://open.metu.edu.tr/handle/11511/104525>. The Middle East Technical University.
- Thara, D. K., PremaSudha, B. G., & Fan, X. (2019). Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques. *Pattern Recognition Letters*, 128(1 December 2019), 544–550. <https://doi.org/10.1016/j.patrec.2019.10.029>
- The Institute of Internal Audit Foundation. (2023). Risk in focus 2024 survey results, global summary. In *The IIA*. Internal Audit Foundation. <https://www.theiia.org/en/internal-audit-foundation/latest-research-and-products/risk-in-focus/>
- The World Economic Forum. (2024). The global risks report 2024 19th edition insight report. In *Weforum*. Weforum. <https://www.weforum.org/publications/global-risks-report-2024/>
- The World Trade Organization (WTO). (2023). *Global trade outlook and statistics: Vol. Update: October 2023*. WTO Publications. https://www.wto.org/english/res_e/booksp_e/gtos_updt_oct23_e.pdf
- The World Bank (2024). *Percentage of GDP from trade in goods and services*. [World Bank national accounts data, and OECD National Accounts data files]. <https://data.worldbank.org/indicator/NE.TRD.GNFS.ZS>
- The Institute of International Finance, & Ernst & Young. (2022). IIF and EY survey report on machine learning uses in credit risk and AML applications . In *The Institute of International Finance*. https://www.iif.com/portals/0/Files/content/32370132_iif_and_ey_survey_report_on_machine_learning_-_uses_in_credit_risk_and_aml_applications_-_public_summary.pdf
- Thomas, L. C. (2000). A survey of credit and behavioural scoring: Forecasting financial risk of lending to consumers. *International Journal of Forecasting*, 16(2), 149–172. [https://doi.org/10.1016/s0169-2070\(00\)00034-0](https://doi.org/10.1016/s0169-2070(00)00034-0)
- Thomas, L., Crook, J., & Edelman, D. (2017). *Credit scoring and its applications* (2nd ed.). SIAM-Society for Industrial and Applied Mathematics.
- Thomas, T., & Rajabi, E. (2021). A systematic review of machine learning-based missing value imputation techniques. *Data Technologies and Applications*, 55(4), 558–585. <https://doi.org/10.1108/dta-12-2020-0298>
- Tirole, J. (2006). *The theory of corporate finance*. Princeton University Press.
- Tiwari, A. (2022). Supervised learning: From theory to applications. In R. Pandey, S. K. Khatri, N. K. Singh, & P. Verma (Eds.), *Artificial Intelligence and Machine Learning for EDGE Computing* (pp. 23–32). Academic Press. <https://doi.org/10.1016/b978-0-12-824054-0.00026-5>
- Turjo, A. A., Karim, S. M. M., Biswas, T. H., Rahman, Y., & Dewan, I. (2021). *Comparative analysis and implementation of credit risk prediction through distinct machine learning models* [Bachelor's Thesis]. Brac University.
- Tüfekci, P., & Önal, Ç. M. (2023). Kötü amaçlı yazılım tespiti için makine öğrenmesi algoritmalarının kullanımı. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 307–319.

<https://doi.org/10.29130/dubited.1287453>

- Türkiye Bankalar Birliği Risk Merkezi. (2024a). Karşılıksız İşlemi Yapılan Çekler. (2020-2024 Ocak). [Finansal Veri Seti]. <https://www.riskmerkezi.org/tr/istatistikler/23>
- Türkiye Bankalar Birliği Risk Merkezi. (2024b). Protestolu senet. (2020-2024 Ocak). [Finansal Veri Seti]. <https://www.riskmerkezi.org/tr/istatistikler/23>
- Tütüncü, T. E., & Gürsakal, S. (2023). Kredi temerrüt riskini tahmin etmede makine öğrenme algoritmalarının karşılaştırılması. *European Journal of Science and Technology*, 2023(50). <https://doi.org/10.31590/ejosat.1171611>
- Uğuz, S. (2021). *Makine öğrenmesi teorik yönleri ve Python uygulamaları ile bir yapay zekâ ekolü* (2. Baskı). Nobel Akademik Yayıncılık.
- Uludağ, O., & Gürsoy, A. (2021). Financial risk estimation with KNN classification algorithm on determined financial ratios. *European Journal of Science and Technology*, 29(Special Issue 2021), 26–29. <https://doi.org/10.31590/ejosat.1001663>
- Urgiriye, A., & Bhartiya, R. (2020). Review of machine learning algorithm on cancer dataset. *International Journal of Scientific Research & Engineering Trends*, 6(6), 3259–3267.
- Valášková, K., Gavláková, P., & Dengov, V. (2014). Assessing credit risk by Moody's KMV model. *Advances in Education Research*, 61, 40–44.
- Valášková, K., & Klieštík, T. (2014). Assessing credit risk by Merton model. *ICMEBIS 2014, International Conference on Management, Education, Business, and Information Science*, 2014, 27–30.
- Vial, G. (2021). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/j.jsis.2019.01.003>
- Vives, X. (2017). The impact of fintech on banking. *European Economy Banks, Regulation, and the Real Sector*, 2017(2), 97–105.
- Vo, T. D., & Tran, M. D. (2021). The impact of Covid-19 pandemic on the global trade. *International Journal of Social Science and Economics Invention*, 7(01), 1–7. <https://doi.org/10.23958/ijssci/vol07-i01/261>
- Wang, J., Xu, J., Cheng, Q., & Kumar, R. (2024). Research on finance credit risk quantification model based on machine learning algorithm. *Academic Journal of Science and Technology*, 10(1), 290–298. <https://doi.org/10.54097/5yzwty57>
- Wang, K., Li, M., Cheng, J., Zhou, X., & Li, G. (2022). Research on personal credit risk evaluation based on XGBoost. *Procedia Computer Science*, 199(7), 1128–1135. <https://doi.org/10.1016/j.procs.2022.01.143>
- Wang, Y., Zhang, Y., Lu, Y., & Yu, X. (2020). A Comparative Assessment of Credit Risk Model Based on Machine Learning ——a case study of bank loan data. *Procedia Computer Science*, 174(2020), 141–149. <https://doi.org/10.1016/j.procs.2020.06.069>
- Weng, J., Meng, Q., & Wang, D. Z. W. (2013). Tree-Based logistic regression approach for


- work zone casualty risk assessment. *Risk Analysis*, 33(3), 493–504. <https://doi.org/10.1111/j.1539-6924.2012.01879.x>
- West, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, 27(11-12), 1131–1152. [https://doi.org/10.1016/s0305-0548\(99\)00149-5](https://doi.org/10.1016/s0305-0548(99)00149-5)
- Widagdo, P., Pratiwi, R. A., Nurlinda, H., Nurbaeti, N., Ismiwati, R., Kurniawan, F. R., & Yusriani, S. (2023). Artificial intelligence in credit risk: A literature review. *Proceeding of the International Seminar on Business Economics Social Science and Technology (ISBEST)*, 3(1). <https://doi.org/10.33830/isbest.v3i1.1472>
- Wilson, N., & Summers, B. (2002). Trade credit terms offered by small firms: Survey evidence and empirical analysis. *Journal of Business Finance Accounting*, 29(3&4), 317–351. <https://doi.org/10.1111/1468-5957.00434>
- Wójcicka-Wójtowicz, A. (2018). Credit risk management in finance - a review of various approaches. *Operations Research and Decisions*, 28(4), 99–106.
- Xanthopoulos, P., Pardalos, P. M., & Trafalis, T. B. (2013). Linear discriminant analysis. In *Robust Data Mining* (pp. 27–33). Springer New York. https://doi.org/10.1007/978-1-4419-9878-1_4
- Xie, W., & Tian, H. (2023). The effect of the COVID-19 pandemic on corporate trade credit financing. *Economics Letters*, 232(November 2023), No: 111339. <https://doi.org/10.1016/j.econlet.2023.111339>
- Xu, Y.-Z., Zhang, J.-L., Hua, Y., & Wang, L.-Y. (2019). Dynamic credit risk evaluation method for e-commerce sellers based on a hybrid artificial intelligence model. *Sustainability*, 11(19), No: 5521. <https://doi.org/10.3390/su11195521>
- Yağlı, İ., & Topcu, M. (2023). Determinants of credit risk in the Turkish banking sector: Does ownership matter? *Sosyoekonomi*, 31(55), 49–67. <https://doi.org/10.17233/sosyoekonomi.2023.01.03>
- Yang, S. A., & Birge, J. R. (2018). Trade credit, risk sharing, and inventory financing portfolios. *SSRN Electronic Journal*, 64(8), 3667–3689. <https://doi.org/10.2139/ssrn.2746645>
- Yang, Y., Gu, J., & Zhou, Z. (2016). Credit risk evaluation based on social media. *Environmental Research*, 148(July 2016), 582–585. <https://doi.org/10.1016/j.envres.2015.12.024>
- Yang, Z. (2014). Utilization of quantization method on credit risk assessment. *Applied Mechanics and Materials*, 472, 432–436. <https://doi.org/10.4028/www.scientific.net/amm.472.432>
- Yazdanfar, D., & Öhman, P. (2015). The impact of credit supply on sales growth: Swedish evidence. *International Journal of Managerial Finance*, 11(3), 329–340. <https://doi.org/10.1108/ijmf-07-2014-0110>
- Yazıcı, M. (2018). Kredi risk analizlerinde diskriminant analizi, lojistik regresyon ve yapay sinir ağlarının karşılaştırılması. *Maliye Finans Yazıları*, 1(109), 91–106.

<https://doi.org/10.33203/mfy.393348>

- Yu, L., Li, X., Tang, L., Zhang, Z., & Kou, G. (2015). Social credit: a comprehensive literature review. *Financial Innovation*, 1(1), No: 6. <https://doi.org/10.1186/s4085401500056>
- Yu, L., Wang, S., & Lai, K. (2008). Credit risk assessment with a multistage neural network ensemble learning approach. *Expert Systems with Applications*, 34(2), 1434–1444. <https://doi.org/10.1016/j.eswa.2007.01.009>
- Yurdakul, F. (2014). Macroeconomic modelling of credit risk for banks. *Procedia- Social and Behavioral Sciences*, 109(8 January 2014), 784–793. <https://doi.org/10.1016/j.sbspro.2013.12.544>
- Yüksel, S. (2017). Determinants of the credit risk in developing countries after economic crisis: A case of Turkish banking sector. In Ü. Hacıoğlu & H. Dinçer (Eds.), *Global Financial Crisis and Its Ramifications on Capital Markets: Opportunities and Threats in Volatile Economic Conditions* (pp. 401–415). Springer International Publishing. https://doi.org/10.1007/9783319470214_28
- Zamore, S., Ohene Djan, K., Alon, I., & Hobdari, B. (2018). Credit risk research: Review and agenda. *Emerging Markets Finance and Trade*, 54(4), 811–835. <https://doi.org/10.1080/1540496x.2018.1433658>
- Zhang, D., & Sogn-Grundvåg, G. (2022). Credit constraints and the severity of COVID-19 impact: Empirical evidence from enterprise surveys. *Economic Analysis and Policy*, 74(June 2022), 337–349. <https://doi.org/10.1016/j.eap.2022.03.005>
- Zhang, T., Zhu, W., Wu, Y., Wu, Z., Zhang, C., & Hu, X. (2023). An explainable financial risk early warning model based on the DS-XGBoost model. *Finance Research Letters*, 56(September 2023), No: 104045. <https://doi.org/10.1016/j.frl.2023.104045>
- Zhang, Y., Liu, H., Li, S., & Xing, C. (2023). The digital transformation effect in trade credit uptake: The buyer perspective. *Emerging Markets Finance and Trade*, 59(7), 2056–2078. <https://api.semanticscholar.org/CorpusID:256970337>
- Zhou, L., Lai, K. K., & Yu, L. (2010). Least squares support vector machines ensemble models for credit scoring. *Expert Systems with Applications*, 37(1), 127–133. <https://doi.org/10.1016/j.eswa.2009.05.024>
- Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59–82. <https://doi.org/10.2307/2490859>

EKLER

EK 1: Kredi Riski ve Makine Öğrenmesi Akış Şeması



Kaynak: Yazar tarafından oluşturulmuştur.

EK 2: Akış Şeması Açıklamaları

AKIŞ ŞEMASI AÇIKLAMALARI		
1	Kredi verisinin toplanması	Müşterilere ait kurum içi verilerin ve dış kaynaklardan ekonomik verilerin çıkarılması ve verilerin seçilmesi
2	Verilerin tek bir veri seti haline getirilmesi	Kurum içi verilerin müşteri ID veya Fatura ID gibi benzersiz değerleri üzerinden ve ekonomik verilerin ilgili dönemlerine göre Python programlama dili aracılığıyla birleştirilmesi
3	Keşifçi veri analizinin yapılması	Değişkenlerin tanımlayıcı istatistiklerinin incelenmesi, verilerin histogram grafikleri ile dağılımlarının incelenmesi, veri tiplerinin tespit edilmesi ile numerik ve kategorik değişkenlerin oluşturulması
4	Verilere ön işleme sürecinin ve özellik mühendisliğinin uygulanması	Verilere ait eksik ve aykırı değerlerin tespit edilmesi, veri tiplerinin tespit edilerek kullanıma uygun hale getirilmesi, hedef değişkenin belirlenmesi ve veriler arasındaki korelasyon ilişkisinin incelenmesi, yeni değişkenlerin oluşturulması, verileri ölçeklendirme
5	Modellemenin makine öğrenmesi yöntemleri ile uygulanması ve performansın değerlendirilmesi	Nihai değişkenler ile oluşturulan modelin eğitim ve test seti olarak ayrılması, model sonuçlarının performans değerlendirme metrikleri ile ölçülmesi, en iyi modele hiper parametre ayarlaması yapılması ve optimize edilmesi
6	Sistemsel entegrasyon ve kredi risk kararı	Modelin gösterge tablosu, uygulama veya benzeri sistemsel yapılara entegre edilmesi, sürekli izleme ve gerekli hallerde güncellemelerin yapılması