

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

YATIRIM PROJELERİNDE RİSK ANALİZİNİN MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE DEĞERLENDİRİLMESİ

Dilan ÖZCAN YAYLALI

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2025

Her hakkı saklıdır

ÖZET

Doktora Tezi

YATIRIM PROJELERİNDE RİSK ANALİZİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE DEĞERLENDİRİLMESİ

Dilan ÖZCAN YAYLALI

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İman ASKERBEYLİ

Bir sabit sermaye yatırım önerisi olarak yatırım projeleri ekonomik büyüme açısından vazgeçilmez öneme sahiptir. Yatırım projelerinin geleceğe dair bir yatırım önerisi olması nedeniyle, geleceğin beraberinde getireceği risklere maruzdur. Çeşitli risk değişkenleri ve belirsizlikten kaynaklanabilecek önemli mali kayıplar göz önüne alındığında, yatırım projelerinin risk analizi özellikle önemlidir. Risk faktörleri arasında projenin karlılığını, getirisini, ekonomik sürdürülebilirliğini doğrudan belirleyen risk faktörü fiyat parametresidir. Bu çalışma, yatırım projelerinde risk analizinde en etkili değişkenlerden biri olması nedeniyle makine öğrenmesi yöntemleri ile fiyat tahmini yapmakta ve yeni bir makine öğrenmesi modeli ortaya koymaktadır. Çalışmada giriş katmanı, tek boyutlu konvolüsyon katmanı, havuzlama katmanı, LSTM gizli katmanı ve tam bağlı katmandan oluşan yeni bir CNN-LSTM makine öğrenmesi modeli geliştirilmiştir. Veri seti olarak 1 Haziran 1996'dan 1 Şubat 2025'e kadar 10228 günü kapsayan oksijen endeksi fiyatları kullanılmıştır. Modelin tahmin değerleri ve performans metrikleri MLP, CNN, LSTM, RNN ve CNN-RNN modelleriyle karşılaştırılmıştır. Oluşturulan CNN-LSTM modeli $RMSE = 0.138$, $MAE = 0.124$, $MAPE = \%2.8$, $MA = \%97.2$ ve $R^2 = 0.9847$ değerleriyle hata ölçüt endekslerinde en başarılı ve model uyumunda diğer modellere kıyasla en iyi performansı göstermiştir.

Eylül 2025, 66 sayfa

Anahtar Kelimeler: Makine Öğrenmesi, Yatırım Projeleri, Risk Analizi

ABSTRACT

PhD Thesis

EVALUATION OF RISK ANALYSIS IN INVESTMENT PROJECTS BY MACHINE LEARNING METHODS

Dilan ÖZCAN YAYLALI

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. İman ASKERBEYLİ

As a fixed capital investment proposal, investment projects are indispensable for economic growth. Because investment projects are future-oriented, they are exposed to the risks that the future may bring. Given the various risk variables and the significant financial losses that can arise from uncertainty, the risk analysis of investment projects is particularly important. Among the risk factors, the price parameter is the one that directly determines the profitability, return, and economic sustainability of a project. This study utilizes machine learning methods to predict prices and presents a new machine learning model because it is one of the most influential variables in risk analysis in investment projects. In this study, a new CNN-LSTM machine learning model consisting of an input layer, a one-dimensional convolution layer, a pooling layer, an LSTM hidden layer, and a fully connected layer was developed. The dataset used was oxygen index prices covering 10,228 days from June 1, 1996, to February 1, 2025. The model's prediction values and performance metrics were compared with those of MLP, CNN, LSTM, RNN, and CNN-RNN models. The presented CNN-LSTM model showed the best performance compared to other models in error metric indices and accuracy rates with values of RMSE = 0.138, MAE = 0.124, MAPE = 2.8%, MA = 97.2% and $R^2 = 0.9847$.

September 2025, 66 pages

Key Words: Machine Learning, Investment Projects, Risk Analysis

ÖNSÖZ ve TEŞEKKÜR

Doktora öğrenimim boyunca ve özellikle tez çalışmam sürecinde akademik birikimlerini, rehberliklerini, manevi desteklerini ve sabrını hiçbir zaman esirgemeyen, her aşamada yol gösterici olan çok kıymetli danışman Hocam Prof. Dr. İman ASKERBEYLİ'ye en içten şükranlarımı ve saygılarımı sunarım.

Doktora tez izleme ve savunma süreçlerinde yapıcı değerlendirmeleri, yönlendirici katkıları ve motivasyon verici yaklaşımlarıyla tezimin gelişimine önemli ölçüde katkı sağlayan Prof. Dr. Halil SARIASLAN ve Prof. Dr. Gazi Erkan BOSTANCI'ya en derin teşekkürlerimi sunarım. Değerli jüri üyeleri Prof. Dr. Nizami GASİLOV ve Dr. Öğr. Üyesi Şifa ÖZSARI'ya minnetlerimi sunarım.

Bu uzun ve zorlu süreçte her zaman arkamda olan, sabırları, sevgileri, destekleri ve emekleriyle bana durmadan güç veren canım annem Fatoş ÖZCAN, canım babam Mehmet Mustafa ÖZCAN'a sonsuz teşekkürler ederim. Tatlılığı ve varlığıyla sürecimi kolaylaştıran sevgili kardeşim Mehmet Miran ÖZCAN'a; hayatıma yeni bir pencere açıp uğur getiren eşim Ramazan YAYLALI'ya çok teşekkür ederim.

Dilan ÖZCAN YAYLALI
Ankara, Eylül 2025

İÇİNDEKİLER

TEZ ONAYI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ ve TEŞEKKÜR.....	iv
KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ.....	1
1.1 Tezin Kapsamı/Amacı	3
1.2 Tez Kapsamında Yapılan Çalışmalar	4
2. KURAMSAL TEMELLER VE LİTERATÜR TARAMASI.....	5
2.1 Yatırım Projelerinde Risk Analizi.....	5
2.2 Risk Türleri	8
2.2.1 Risk literatürü.....	12
2.3 Makine Öğrenmesi.....	16
2.3.1 Makine öğrenmesi yaklaşımları.....	19
2.4 Derin Öğrenme Yöntemleri	21
2.4.1 Evrişimli sinir ağları (CNN)	29
2.4.2 Uzun kısa zamanlı hafıza (LSTM)	32
2.4.3 Tekrarlayan sinir ağı (RNN)	33
2.4.4 CNN - LSTM modeli	35
3. MATERYAL/METOT.....	43
3.1 Materyal	43
3.1.1 Veri seti	43
3.1.2 Değerlendirme	43
3.1.3 Uygulama	44
4. ARAŞTIRMA BULGULARI.....	47
5. TARTIŞMA	54
6. SONUÇ.....	57
KAYNAKLAR	59
ÖZGEÇMİŞ.....	66

KISALTMALAR DİZİNİ

ADAM	Adaptive Moment Estimation
BPTT	Back Propagation Through Time
CART	Classification and Regression Trees
CNN	Convolutional Neural Network
CRF	Conditional Random Field
DVM	Destek Vektör Makineleri
EKK	En Küçük Kareler
ELM	Extreme Learning Machine
ES	Expected Shortfall
FRED	Federal Reserve Economic Data
IRR	Internal Rate of Return
GAN	Generative Adversarial Networks
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
GELM-RBF	Generalized Extreme Learning Machine Radial Basis Function
GLU	Gated Linear Unit
KNN	K-Nearest Neighbors
LASSO	Least Absolute Shrinkage and Selection Operator
LSTM	Long Short-Term Memory
MA	Mean Accuracy
MAE	Mean Average Error
MAPE	Mean Average Percentage Error
MARS	Multivariate Adaptive Regression Splines
MLP	Multilayer Perceptron
NPV	Net Present Value
Relu	Rectified Linear Unit
RMSE	Root Mean Squared Error
RNN	Recurrent Neural Networks
VaR	Value at Risk
VAR	Vector Autoregression
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 2.1 Yapay sinir ağları	18
Şekil 2.2 Bayesyan ağlar	18
Şekil 2.3 En küçük kareler yöntemi	20
Şekil 2.4 K-en yakın komşuluk yöntemi	20
Şekil 2.5 Destek vektör makineleri yöntemi	21
Şekil 2.6 CNN nitelik vektörü oluşturulması	30
Şekil 2.7 CNN modeli genel görünüm	31
Şekil 2.8 CNN modelinin matris gösterimi	32
Şekil 2.9 LSTM modeli	33
Şekil 2.10 Basit RNN modeli yapısı	34
Şekil 2.11 Kompleks RNN modeli genel yapısı	34
Şekil 2.12 RNN modeli vektör ve matris dönüşümleri	35
Şekil 2.13 CNN-LSTM mimarisi	37
Şekil 2.14 Yatırım riskleri tahmin modeli	41
Şekil 2.15 CNN ve LSTM bellek hücresi mimarisi	41
Şekil 2.16 CNN-LSTM modeli akış diyagramı	42
Şekil 3.1 CNN-LSTM Modelinin yapısı	46
Şekil 4.1 MLP modeli tahmin edilen değer ile gerçek değer karşılaştırması	47
Şekil 4.2 CNN modeli tahmin değeri ile gerçek değer karşılaştırması	47
Şekil 4.3 RNN modeli tahmin edilen değer ile gerçek değer karşılaştırması	48
Şekil 4.4 LSTM modeli tahmin edilen değer ile gerçek değer karşılaştırması	48
Şekil 4.5 CNN-RNN tahmin edilen değer ile gerçek değer karşılaştırması	49
Şekil 4.6 CNN-LSTM tahmin edilen değer ile gerçek değer karşılaştırması	49
Şekil 4.7 Farklı makine öğrenmesi yöntemlerinin RMSE karşılaştırması	50
Şekil 4.8 Farklı makine öğrenmesi yöntemlerinin MAE karşılaştırması	51
Şekil 4.9 Farklı makine öğrenmesi yöntemlerinin MAPE karşılaştırması	51
Şekil 4.10 Farklı makine öğrenmesi yöntemlerinin MA karşılaştırması	52
Şekil 4.11 Farklı makine öğrenmesi yöntemlerinin R^2 karşılaştırması	52
Şekil 4.12 Makine öğrenmesi yöntemlerinin gürültü altında çalışma sonuçları	53

ÇİZELGELER DİZİNİ

Çizelge 2.1 Risk analizi araçları.....	11
Çizelge 2.2 Literatürü özetleri.....	13
Çizelge 2.3 Endüstride uygulanan çalışmalar	15
Çizelge 3.1 CNN-LSTM modeli parametre değerleri.....	45
Çizelge 4.1 Farklı makine öğrenmesi modellerinin tahmin karşılaştırılması	50

1. GİRİŞ

Yatırım projelerinde risk analizi çalışmaları giderek daha fazla ivme kazanmakta olup; risklerin tanımlanma biçimi, ölçümü, raporlanması ve yönetilmesi hem akademi hem de endüstride yapılan önemli araştırmalara konu olmaktadır. Yapay zekanın iş uygulamalarındaki etkisinin giderek artmasıyla, risk araştırmaları yön değiştirmiş; risk analizlerinde makine öğrenimi yöntemleri araştırılmaya ve uygulanmaya başlanmıştır.

Helbakkmo ve diğerlerinin 2013'te yaptıkları çalışmada, 2025 yılına gelindiğinde yatırım projelerindeki risk analizi uygulamalarının o zamankinden kökten farklı olacağı vurgulanmıştır. 2018 yılı ve öncesindeki çalışmalara baktığımızda risk analizi uygulamalarının daha çok risk türlerine ve ekonomik modellere odaklandığını farkederken; 2018 yılı sonrasında veri madenciliği, yapay zeka, makine öğrenmesi ve derin öğrenme yöntemlerindeki gelişmelerin yüksek seviyede seyretmesiyle risk analizi uygulamaları makine öğrenmesinin doğası gereği verilerden model üretmeye doğru evrilmiştir. Makine öğrenimi büyük veri kümeleri içindeki karmaşık, doğrusal olmayan kalıpları belirleyerek daha doğru risk modellerinin oluşturulmasını sağlayabilmekte ve eklenen her bilgiyle tahmin gücü zaman içinde daha da artmaktadır.

Yatırım projelerinin risk analizi, önemli ekonomik kayıplar oluşturabilecek risk faktörlerinin belirlenmesi açısından büyük önem taşımaktadır. Bir yatırımın öneri aşamasından önce detaylı bir şekilde hazırlanması ve değerlendirilmesi gerekir; bu, yatırım kavramının makro açıdan bir ülkenin ekonomisine ve mikro açıdan ise işletmenin faaliyetlerine önemli katkılar sağlar. Ekonomik büyümede temel unsur olan yatırımların, makro düzeyde ekonomide ve mikro seviyede çeşitli dinamikleri etkilediği bilinmektedir. Yatırım, “çoğaltan” ya da “çarpan” etkileriyle ekonomi üzerinde güçlendirici ve hızlandırıcı rol oynayabilir. Makro düzeyde yatırımların çoğaltan etkisi, toplam harcamaların katlanarak milli gelirden önemli bir artışa yol açmasını sağlar. Bu etkinin büyüklüğü, ekonomideki marjinal tasarruf eğilimiyle ters yönde olup, katsayıyla ifade edilir. Bir başka deyişle, toplam tasarruf oranının toplam gelirden fazla olması, yatırımların artışını teşvik eder. Bu durumda, yatırım oranları sabit tutulduğunda, ekonomik büyüme hızlanacaktır. Ayrıca, ekonomik büyümenin devamı için yatırımların

sürdürülebilirliği ve toplam harcamaların düzenli artması gerekir. Artan yatırımlar, talep ve gelirleri artırır; böylece talep arttıkça yeni yatırımlar tetiklenir ve ekonomik döngü hızlanır. Bu süreç, sürdürülebilir büyüme ve kalıcı gelişme için temel bir mekanizmadır.

Bu iki önemli makro ekonomik ilkeye göre, yatırımlar ekonomik büyümenin vazgeçilmez temel unsurlarındandır. Bu nedenle, sınırlı kaynakların etkin kullanımı ve ekonomik büyümenin sağlanması için, yatırım projelerinin dikkatli ve bilimsel temellere dayalı olarak planlanması ve en uygun olanların seçiminde dikkatli olunması gerekir. Kaynakların optimum kullanımı, mevcut kısıtlamalar içinde en yüksek fayda ve verimlilik sağlayacak biçimde kullanılmasını amaçlar ve bu, sürdürülebilir kalkınma için temel ilkedir. Optimum kaynak kullanımı, kaynakların farklı alanlara tahsis edilmesinde en yüksek faydayı sağlayacak kararların alınmasını ve kaynakların alternatif kullanım alanlarından en iyi şekilde yararlanılmasını ifade eder. Bu süreçte, kaynakların farklı alanlara tahsisi ve hangi alanlarda kullanılacağı, fırsat maliyetlerinin ve avantajların dikkate alınarak belirlenir. Sonuç olarak, ekonomik kalkınma ve büyüme için yatırım kararlarının dikkatli ve bilinçli alınması, sürdürülebilirlik ve yüksek verimlilik açısından büyük önem taşımaktadır.

Tez çalışmasının birinci bölümünde tezin amaç, kapsam ve özgün değeri açıklanmıştır. Tez kapsamında yapılan çalışmalar hakkında bilgi verilmiştir.

İkinci bölümde yatırım projelerinin risk analizine dair bilgiler verilmiştir. Yatırım projelerinin risk analizinde kullanılan yöntemler açıklanmış, risk türleri belirtilmiş ve kapsamlı bir literatür taraması ortaya konmuştur. Ardından makine öğrenmesi ve derin öğrenme hakkında bilgiler verilmiş; kaynaklar detaylıca özetlenmiştir. Tez çalışması kapsamında kullanılan CNN, LSTM, RNN modelleri ve geliştirilen CNN-LSTM modeli ayrıntılı olarak açıklanmıştır.

Üçüncü bölümde tez çalışmasında kullanılan veri seti hakkında bilgiler verilmiştir. Verilere uygulanan ön işleme aşamaları olan yeniden ölçeklendirme, normalizasyon ve veri çoğaltma hakkında bilgi aktarılmıştır. Geliştirilen sistem tasarımları ayrıntılı bir

şekilde aktarılmıştır. Sisteme eklenen ve performansa etkileri ölçülen modüller kapsamlı bir şekilde incelenmiştir.

Dördüncü bölümde araştırma bulguları olarak tez çalışmasında geliştirilen sistemlerin performansları elde edilip karşılaştırılmalı olarak sunulmuştur.

Beşinci bölümde geliştirilen sistem ile elde edilen sonuçlar hakkında bilgi verilmiştir. Geliştirilmesi ile ilgili öneriler ve iyileştirmeler sunulmuştur.

1.1 Tezin Kapsamı/Amacı

Bir sabit sermaye yatırım önerisi olarak yatırım projeleri ekonomik büyüme açısından vazgeçilmez öneme sahiptirler. Yatırım projeleri, makro düzeyde bir ülke ekonomisi ve mikro düzeyde bir işletmenin operasyonel sürdürülebilirliği için elzemdir. Ekonomik büyüme için elzem olan sabit sermaye yatırımları, kapsamı nedeniyle önemli harcamalar gerektirir ve tedarik, üretim, personel, pazarlama ve finans dahil olmak üzere tüm işletme faaliyetlerini anında etkiler. Yanlış yönlendirilmiş, verimsiz ve kârsız sektörlere yapılan önemli yatırımlar, şirketin mevcut faaliyetlerini ve gelecekteki konumunu anında tehdit edecektir. Bununla birlikte, geleceğin belirsizliklerle dolu olduğu ve beraberinde getireceği sosyoekonomik dönüşümlerin, bir projenin uzun operasyonel aşaması boyunca mikroekonomik dengelerden makroekonomik göstergelere kadar her şeyi değiştirebileceği yaygın olarak kabul edilmektedir. Bu değişiklikler, projenin başlangıcında belirlenen tüm projeksiyonları ve beklenen sonuçları etkileyecektir. Geleceğe yönelik bir sabit sermaye yatırım teklifi olan bir yatırım projesi, gelecekteki sosyoekonomik değişikliklere açıktır ve bu nedenle kaçınılmaz riskler içerir. Sonuç olarak, bir yatırım projesiyle ilişkili içsel riskleri veya değişiklikleri değerlendirmek ve ölçmek için kapsamlı bir risk analizi gerçekleştirmek, bilinçli yatırım kararları almak açısından hayati önem taşımaktadır.

1.2 Tez Kapsamında Yapılan Çalışmalar

Yatırım projelerinde risk analizi yaparken çok sayıda faktör ve tekniğin dikkate alınması gerekir. Çok sayıda risk ve belirsizlik içeren öngörülemeyen belirsiz bir gelecek, fizibilite ve karlılık için beklenen sonuçları sıklıkla etkiler. Duyarlılık analizi, olasılık analizi, eşik analizi, karar ağaçları, belirsizlik analizi ve Monte-Carlo simülasyon tekniği iyi bilinen ve yaygın olarak kullanılan yaklaşımlardır (Sarıaslan 2019). Literatür ve değerlendirme raporlarının incelenmesine göre; bu tür değerlerin değerlendirilmesinin, özellikle oksijen üretimi gibi enerji yatırım projeleri için anlamlı bir karar için yeterli bilgi sağlamadığı görülmektedir. Derin öğrenme algoritmaları, risk veya yatırım alanında kapsamlı bir şekilde incelenmiştir. Yatırımcıların yatırım stratejisini ve getiri oranını iyileştirmek için Xie ve Liu, derin öğrenmenin finansal veri işleme ve yatırım modelleri ile yatırım planı oluşturmada kullanımını incelemişlerdir (Liu 2019, Xie vd. 2020). Sohangir ve diğerleri tarafından ise finansal tahmin için en etkili modelin Evrişimli Sinir Ağı (CNN) olduğu gösterilmiştir. Başka bir araştırma ise finansal risk tahminlerinin doğruluğunun ve yatırım portföylerinin optimizasyonunun kritik olduğunu bulmuştur. Bu nedenle sınıflandırmada Uzun Kısa Süreli Bellek (LSTM) ve Yinelemeli Sinir Ağı'nın (RNN) performansı karşılaştırılmış; sonuçlarda LSTM'nin daha iyi bir performansa sahip olduğunu ve bunun yatırım karlarını maksimize etmek için büyük önem taşıdığını göstermiştir (Lu vd. 2020, Song 2021). Mevcut çalışmalara dayanarak ilgili tezde yatırım projeleri için bir risk değerlendirme modeli oluşturmak ve yatırım risklerini bilimsel ve etkili bir şekilde analiz etmek için özel bir makine öğrenmesi yaklaşımı tekniği olan CNN-LSTM modeli geliştirilmiştir. Görsel alandaki belirgin unsurlara odaklanmasıyla öne çıkan CNN ile zamansal dizilere göre genişleme yeteneğine sahip ve zaman serisi analizinde yaygın olarak kullanılan LSTM modellerinin birleştirilmesiyle CNN ve LSTM'nin özelliklerine dayalı bir fiyat tahmin modeli oluşturulmuştur. Ardından modelimizin performansı MLP, CNN, RNN, LSTM, CNN-RNN modelleriyle karşılaştırılmıştır. Tez kapsamında oluşturduğumuz modelimiz diğer makine öğrenmesi yöntemleriyle karşılaştırılarak 24 Ağustos 2022 tarihli Bakü Azerbaycan'da gerçekleşen 8. Uluslararası Endüstri Uygulamalarıyla Kontrol ve Optimizasyon Konferansı'nda (COIA) ve geliştirilerek yeni veri setleriyle 26 Ağustos 2025 tarihinde Bakü Azerbaycan'da gerçekleşen 6. Uluslararası Siberetik ve Enformatik Problemleri Konferansı'nda (PCI) sunulmuştur.

2. KURAMSAL TEMELLER VE LİTERATÜR TARAMASI

2.1 Yatırım Projelerinde Risk Analizi

Projelerin risklerini belirlemek amacıyla duyarlılık analizi, olasılık analizi, başabaş analizi ve faydalı katkıları ölçmek gibi yöntemler kullanılmaktadır. Duyarlılık analizi, belirli bir yatırımın kesinlik prensipleri çerçevesinde ve alan değişkenleri ile parametrelerin nasıl ve hangi derecede projenin getirilerini etkilediğini inceleyen bir yaklaşımdır. Bu yöntemin temel amacı, yatırım projesini ilgilendiren herhangi bir değişkenin (fiyat, satış miktarı, ekonomik oranlar vb.) olası değişimlerinin projenin karlılığı üzerindeki etkisini ortaya koymaktır. Dolayısıyla, duyarlılık analizi sayesinde projenin en çok etki eden kritik değişkenleri belirlenir. Bu değişkenlerin olası değişimlere karşı aldığı önlemler önceden planlanabilir ve böylece gerekli önlemler alınabilir.

Genellikle uygulamada duyarlılık analizi yapmak için en yaygın kullanılan yöntem; “İndirgenmiş Nakit Akımları” prensibiyle çalışan, net bugünkü değer ya da iç karlılık oranı olarak bilinen yöntemlerdir. Bu yöntemler, bir yatırım projesinin kapsadığı tüm maliyet ve gelirlerin zaman içindeki değişimini düzgün bir biçimde yansıtan nakit giriş ve çıkışlarını temel alır. Ayrıca, yatırımın nihai sonucunu belirleyen karlılık oranını veya net bugünkü değeri açıkça ortaya koyar. Bu nedenle, projenin maliyet ve gelir değişkenlerinden herhangi birinin değerinde yapılacak değişiklikler, diğer tüm değişkenler sabit tutulmak kaydıyla, toplam projenin sonucuna ne kadar etki edeceğini net bir biçimde gösterir. Bu bağlamda, projede niteliği gözetilmeksizin, net bugünkü değeri hesaplayan yöntemlerin formülü şu şekilde özetlenebilir.

$$NBD = \sum_{t=0}^n \frac{(G_t - I_t - C_t - F_t - D_t)(1 - V) + D_t}{(1 + r)^t} \quad (1)$$

NBD : Net bugünkü değeri

G : Gelirler

I : İlk yatırım tutarı

- Ç : İşletme giderleri
 F : Faizler
 D : Amortismanlar
 V : Vergi oranını
 r : Sermaye maliyet oranı (iskonto oranı)
 t : Zamanı (yıl bazında, t=0,1,...,n),
 n : Projenin yaşam devri yıl sayısını

Formüle göre gelir (G), temel bir değişkendir. Ancak satılan ürün miktarı (Q) ve birim satış fiyatı (F) gelirleri belirler. Projenin üzerinde kritik etki yarattığı ve projeye katkısı yüksek olduğu için, bu etkiyi dikkate almamak mümkün değildir. Bütün bu nedenlerle, yıl sonunda elde edilen toplam değeri (G) ile ilgili olarak aşağıdaki gibi bir açıklama yapabiliriz.

$$G_t = (Q_t * f_t) + H_n \quad (2)$$

Benzer biçimde ilk yatırım tutarını (I), kapsadığı sabit sermaye yatırım giderleri (S) ve işletme sermayesi (W) değerlerini gösterecek biçimde;

$$I_t = S_t + W_t \quad (3)$$

olarak yazabiliriz. Böylece, G ve I yerine belirleyicileri olan alt değişkenler konulursa yukarıdaki NBD formülü aşağıdaki biçimi alacaktır.

$$NBD = \sum_{t=0}^n \frac{(Q_t * f_t) + H_t - (S_t + W_t) - \text{Ç}_t - F_t - D_t)(1 - V) + D_t}{(1 + r)^t} \quad (4)$$

Duyarlılık analizi, değişim aralığındaki değerlerin olasılık gösterme ihtimalinin bilinmediği durumlarda kullanılır. Genellikle, projeye ilişkin en çok değişkenlik gösterebilecek faktörler belirlenerek, bu değerlerin olasılık dağılımı tespit edilir. Belirli bir aralıkta bir değer ortaya çıkma olasılığını belirlemek amacıyla, kesinlik ve güvenilebilirlik seviyeleri göz önünde bulundurularak, detaylı geçmiş dönem verilerine

ve deneyimlere dayanarak, Bayesyan yaklaşımlarla olasılık dağılımları tahmin edilir; ayrıca, istatistiksel dağılımlara benzetmek ve temel almak amacıyla kullanılır. Sınırlı bilgilerin sözkonusu olduğu durumlarda, proje analisti subjektif bilgi ve deneyimlerine dayanarak değişkenin dağılımını belirler ve bu dağılımın özelliklerini anlamaya çalışır. Kritik değişkenler için standart istatistiksel dağılımlar kullanılırken, Poisson'a dayalı, negatif üssel ve benzeri dağılımlar tercih edilir. Başabaş analizi ve faaliyet karlılığı gibi kararlar, toplam risk ve belirsizlik durumlarında, toplam riskin nasıl dağıldığını gösteren, ve benzer istatistiksel dağılımlarla anlamaya çalışan yaklaşımlar üzerinde yoğunlaşır. Kritik değişkenler, standart istatistiksel dağılımların kullanılmadığı durumlarda, belli bir olasılık değeriyle doğrulanır ve bu dağılımın özelliklerini anlamaya çalışır. Riskli projelerde, toplam risk ve olasılık dağılımları dikkate alınmadan, projeye ilişkin risk ve belirsizlikler değerlendirilir. Bu, toplam risklerin nasıl dağıldığını ve projedeki risklerin toplamını gösterir. Ayrıca, varyans ve standart sapma gibi istatistiksel teknikler kullanılarak, beklenen değer, değişim katsayısı ve olasılık dağılımı gibi göstergeler hesaplanır. Bu teknikler, projelerde risk analizi ve en uygun yatırım kararlarının alınmasında kritik öneme sahiptir. Bu nedenle, toplam risk ve belirsizlikler, yatırımın finansal riskiyle birlikte dikkate alınmalıdır; böylece, toplam risklerin nasıl dağıldığı ve projeden beklenen getiri ile risklerin ilişkisi net bir şekilde gösterilebilir. Ayrıca, projeye ilişkin risklerin değerlendirilmesi sırasında, kullanılan istatistiksel değerler ve teknikler, projeye özgü olmalı ve karar vericilerin anlayacağı şekilde olmalıdır. Son olarak, yatırım projelerinin risk analizi ve değerlendirilmesi, belirli aşamalar ve teknikler kullanılarak yapılmakta ve böylece, toplam risk ve belirsizlikler daha iyi anlaşılır.

$$E_t(A) = \sum_{t=0}^n A_{it} * P_{it} \quad (5)$$

(Tüm t'ler için, t=0,1,...,n ve i=1,2,...,k) ve

$$E_t(NBD) = \sum_{t=0}^n \frac{E_t(A)}{(1 + R)^t} \quad (6)$$

olmak üzere;

A	: Herhangi bir yıldaki i'nci net nakit akımı
P	: Herhangi bir yıldaki i'nci net nakımının olasılığı
E(A)	: t yılı için hesaplanan beklenen net nakit akımı
E(NBD)	: Projenin net bugünkü değeri
R	: Risksiz iskonto oranı (sermaye maliyeti oranı)

Yatırım projelerinin risk analizinde farklı yöntemler kullanılabilir. Karar ağaçları yöntemi, yatırım kararlarının net nakit akımları arasındaki bağımlılığın ve toplam bağımsızlığın bulunmadığı durumlarda tercih edilir. Bu yaklaşım, beklenen net bugünkü değer in standart sapmayla hesaplanmasına olanak tanır. Bir başka pratik yöntem ise, doğrudan gerçekçilik ile sistemin temsil edilmesini sağlayan modellere dayanır. Sistemleri temsili modeller kullanılarak, karar vericilerin karar alma süreçleri, belirli teknikler ve simülasyonlar yardımıyla analiz edilir. Bu modellerdeki belirsizlikler ve değişkenlikler, güvenilirlik seviyelerine göre değerlendirilir. İkinci aşamada, farklı kritik değişkenlerin olasılık dağılımları belirlenir; bu dağılımlar, modelin güvenilirliğini ve sonuçların doğruluğunu artırmak amacıyla kullanılabilir. Bu süreçte, sistem parametrelerinin rastgele sayılarla temsil edilmesiyle Monte Carlo simülasyonları gerçekleştirilir. Böylece, toplam risk ve belirsizlikler daha iyi anlaşılır. Son aşamada, her kritik değişken için, dağılım özellikleri temel alınarak, olasılık dağılımları ve rastgele sayılar belirlenir. Bu adımlar, karar vericilerin, projelerdeki riskleri ve belirsizlikleri daha net görmelerini sağlar. Ayrıca, karar sürecinde, varyans ve standart sapma gibi istatistiksel araçlar kullanılarak, risklerin ölçülmesi ve değerlendirilmesi yapılır. Bu teknikler, projeler üzerinde karar verirken, risk ve güvenilirliği dikkate almayı kolaylaştırır. Sonuç olarak, sistemlerin modelleme ve simülasyonlarıyla, belirsizliklerin ve risklerin daha doğru ve güvenilir şekilde analiz edilmesi sağlanır (Sarıaslan, 2019).

2.2 Risk Türleri

Gelir sahipleri için getiriye artırma arayışı, riskin artması pahasına gerçekleşmektedir. Sermaye yatırımı projeleri; piyasa riski, kredi riski, faiz oranı riski, teknolojik risk, operasyonel risk, enflasyon riski, iflas riski, likidite riski gibi çeşitli risklerle karşı karşıyadır. Bu risklerin etkin yönetimi, ekonomik performansının anahtarıdır. Ayrıca, bu

riskler ve yatırım projelerinin finansal sistemlerde oynadığı rol göz önüne alındığında, bu projeler düzenleyici ilgiye tabidir (Saunders vd. 2006). Düzenleyiciler, yatırım projelerinin ortaya çıkabilecek birçok risk için sermaye bulundurmasını şart koşmaktadır. Bankalar için sermaye gerekliliklerinin belirlenmesine yönelik Basel standartları 1998 yılında geliştirilmiş ve o tarihten bu yana geliştirilerek evrim geçirmiştir. Ana risk türlerinin her biri için sermaye gereklidir. Kredi riski geleneksel olarak yatırım projelerinin karşılaştığı en büyük risktir ve genellikle en fazla sermaye gerektiren risktir. Piyasa riski esas olarak bir bankanın ticari faaliyetlerinden kaynaklanırken, operasyonel risk dahili sistem arızalarından veya harici olaylardan kaynaklanan kayıp riskidir. Yasal sermayenin hesaplanmasına ek olarak, çoğu büyük yatırım projesi, düzenleyicilerin reçetelerinden ziyade bir bankanın modellerine dayanan ekonomik sermayeyi de hesaplar (Hull 2012). Sermaye yatırımı projelerinin karşılaştığı başlıca riskler kredi, piyasa ve operasyonel riskler olup likidite, iş ve itibar riski gibi diğer risk türleri de bulunmaktadır. Yatırım projeleri bu riskleri izlemek, yönetmek ve ölçmek için aktif olarak risk analizi yapmaktadır (Apostolik vd. 2009).

Piyasa riski, "piyasa fiyatlarının seviyesindeki veya oynaklığındaki hareketlerden kaynaklanan" kayıp riski olarak tanımlanabilir (Jorion 2007). Faiz riski, faiz oranlarındaki hareketlerden kaynaklanan potansiyel kayıp olarak tanımlanabilir. Hisse senedi riski, bir hisse senedinin fiyatındaki olumsuz bir değişimin sonucunda ortaya çıkan potansiyel kayıp olarak tanımlanabilir. Döviz kuru riski, döviz kurundaki dalgalanmalar nedeniyle bir bankanın varlıklarının veya yükümlülüklerinin değerinin değişmesi riski olarak tanımlanabilir. Emtia riski, elde tutulan emtianın fiyatındaki olumsuz bir değişimden kaynaklanan potansiyel kayıp olarak tanımlanabilir. Basel anlaşmasının piyasa riski çerçevesi, bir iç model yaklaşımı ve bir standartlaştırılmış yaklaşımdan oluşmaktadır. Revize edilen çerçeve, kuyruk riskini daha iyi yakalayabilmek için stres altındaki risk ölçümünde Riske Maruz Değer'den (VaR) Beklenen Açık'a (ES) doğru bir kayma göstermiştir (Basel Bankacılık Denetim Komitesi 2006).

Kredi riski, bir borçlunun yükümlülüklerini (faiz, anapara tutarları) yerine getirememesi durumunda bir bankanın potansiyel zarar riski olarak tanımlanabilir. Kredi riski, sermaye yatırım projelerinin karşılaştığı en büyük risktir (Apostolik vd. 2009). Basel Anlaşması,

yatırım projelerinin kredi riski için içsel derecelendirmeye dayalı yaklaşımı benimsemesine izin vermektedir. Yatırım projeleri, beklenen zararı hesaplamak için kendi kredi riski modellerini dahili olarak geliştirebilir. Tahmin edilmesi gereken temel risk parametreleri temerrüt olasılığı, temerrüt halinde kayıp ve temerrüt halinde maruz kalınan (Basel Bankacılık Denetim Komitesi 2005).

Diğer risklerden ayrı olarak ele alınan likidite riski, varlık likiditesi riski ve fonlama likiditesi riski olmak üzere iki şekilde ortaya çıkmaktadır. Bir banka, normal işlem lotu büyüklüğüne göre pozisyon büyüklüğünün bir sonucu olarak, bir işlemin geçerli piyasa fiyatlarından gerçekleştirilememesi durumunda varlık likiditesi riskine maruz kalır. Fonlama likiditesi riski, nakit akışı yükümlülüklerinin yerine getirilememesi anlamına gelir ve nakit akışı riski olarak da bilinir (Jorion 2007). Yatırım projelerinin, bir dizi stres olayına dayanma kabiliyeti de dahil olmak üzere yeterli likiditenin sürdürülmesini sağlayacak sağlam bir likidite risk analizi çerçevesi oluşturması gerekmektedir. Likidite riskinin tanımlanması, ölçülmesi, izlenmesi ve kontrolü için sağlam bir süreç uygulanmalıdır (Basel Bankacılık Denetim Komitesi 2008).

Operasyonel risk, Basel Bankacılık Denetim Komitesi tarafından "yetersiz veya başarısız iç süreçler, insanlar ve sistemler veya dış olaylardan" kaynaklanan kayıp riski olarak tanımlanır ve sermaye yatırım projelerinde "risk analizinin temel bir unsurudur". Bu tanım yasal riski içerir, ancak stratejik ve itibar riskini hariç tutar. Tüm bankacılık ürünleri, faaliyetleri, süreçleri ve sistemlerinin doğasında var olduğu kabul edilir (Basel Bankacılık Denetim Komitesi 2011). Yıllık raporlarda operasyonel risk farklı şekillerde sunulmuş ve bir dizi alt riski içermiştir ve daha çok finansal olmayan risk olarak adlandırılabilir. Bu riskler arasında dolandırıcılık riski, siber güvenlik, müşteri ürünleri ve iş uygulamaları, bilgi ve esneklik riski, kara para aklama ve mali suç riskleri, tedarikçi ve dış kaynak kullanımı riskleri, teknoloji riski ve iş kesintisi riskleri yer almaktadır. Bazı durumlarda, yatırım projeleri uyum ve yasal riskleri de operasyonel risk altında raporlamıştır.

Literatürde ele alınan çeşitli risk türleri ve bu riskleri yönetmek için kullanılan çeşitli risk analiz araçları (Çizelge 2.1) gösteren çizelge aşağıda yer almaktadır.

Çizelge 2.1 Risk analizi araçları

	Piyasa Riski	Kredi Riski	Likidite Risk	Operasyonel Risk
Risk analizi Araçları				
Duyarlılık Analizi	√	√	√	
Olasılık Analizi	√	√	√	√
Risk Limitleri	√	√	√	
Kredi Riski limitleri		√		
Risk Altındaki Değer	√			
Risk Altındaki Kazançlar	√			
Beklenen Eksiklik	√			
Ekonomik Değer Stres Testi	√			
Ekonomik Sermaye	√	√	√	√
Risk Duyarlılıkları	√			
Risk Değerlendirmesi				√
Operasyonel Risk Kayıpları				√
Kayıp Dağılımı Yaklaşımı				√
Senaryo Analizi	√	√	√	√
Kuyruk Riski Yakalama	√	√	√	√
Stres Testi	√	√	√	√
Puanlama Modelleri		√		
Derecelendirme Modelleri		√		
Maruz kalma				
- Temerrüt Olasılığı				
- Temerrüt Halinde Kayıp		√		
- Temerrüt Durumunda Maruz Kalma				
Geri Test	√	√	√	

2.2.1 Risk literatürü

Risk analizinde makine öğrenimi uygulamalarını araştıran literatürün incelenmesi için, ilgili makalelerin araştırılmasında iki anahtar kelime seti kullanılmıştır. Makale taraması Web of Science, Scopus, scholar.google.com veri tabanları kullanılarak "makine öğrenimi", "risk", "yatırım projeleri" anahtar kelimeleri ile yapılmıştır. Arama ve inceleme konferans bildirilerini, dergi makalelerini, kitapları ve seçilmiş tezleri (yüksek lisans veya doktora) içermektedir.

İncelemede, yalnızca konuyu belirli bir derinlik düzeyinde, yani belirli algoritmalara atıfta bulunarak veya makine öğreniminin nasıl uygulanabileceğine dair bir tasarım veya model sunarak analiz eden makalelere bakılmıştır. Risk analizi alanında makine öğrenimi uygulamasına yalnızca üstünkörü veya genel bir atıfta bulunan makaleler veya bildiriler ya da konferans bildirileri bu araştırma için dikkate alınmamıştır. Yazarların veya konuşmacıların risk yönetiminde makine öğrenimi veya yapay zekanın uygulanabileceğini öne sürdüğü birçok referansın mevcut olduğu belirtilmektedir; ancak bunların bir çoğu hangi algoritmaların kullanılacağı konusunda netlik sağlamamakta veya makine öğrenimi/yapay zekanın bir test veya endüstri kurulumunda nasıl uygulandığına dair örnekler sunmamaktadır.

Bu araştırmanın metodolojik çerçevesi, yatırım projelerinde makine öğrenimi ve risk analizi ile ilgili çeşitli sorun alanları analiz edilerek belirlenmiştir. Makaleler: (i) odaklandıkları risk alanı; (ii) hedefledikleri risk analizi aracı veya risk analizi çerçevesi bileşeni; veya (iii) uygulanan/çalışılan/önerilen algoritmaları anlamak için sınıflandırılmıştır. Anket ayrıca risk değerlendirmesi ve ölçümüne daha fazla odaklanan makaleleri de incelemeyi amaçlamıştır.

İncelenen makalelere genel bir bakış Çizelge 2.2’de yer almaktadır. Tabloda, risk türüne göre sınıflandırılarak incelenen makalelerin bir listesi, ele alınan risk analizi yöntemi/aracı ve uygulamada atıfta bulunulan algoritmalar yer almaktadır.

Çizelge 2.2 Literatür özetleri

Risk Türü	Risk Analizi Yöntemi/Aracı	Kaynak	Algoritma
Kredi Riski	Puanlama Modelleri	Bellotti ve Crook 2009	DVM
Kredi Riski	Puanlama Modelleri	Galindo ve Tamayo 2000	Karar Ağaçları, YSA, K-En Yakın Komşuluk
Kredi Riski	Puanlama Modelleri	Wang vd. 2015	Lojistik Regresyon
Kredi Riski	Puanlama Modelleri	Hamori vd. 2018	Rastgele Orman
Kredi Riski	Puanlama Modelleri	Harris 2013	DVM
Kredi Riski	Puanlama Modelleri	Huang vd. 2007	DVM
Kredi Riski	Puanlama Modelleri	Keramati ve Yousefi 2011	YSA, Bayesyan ağlar, K-En Yakın Komşuluk, DVM
Kredi Riski	Puanlama Modelleri	Khandani vd. 2010	Karar Ağaçları
Kredi Riski	Puanlama Modelleri	Lai vd. 2006	DVM
Kredi Riski	Puanlama Modelleri	Lessmann vd. 2015	Genetik Algoritmalar
Kredi Riski	Puanlama Modelleri	Van-Sang ve Nguyen 2016	Derin Öğrenme
Kredi Riski	Puanlama Modelleri	Yu vd. 2016	Derin Öğrenme, Makine Öğrenmesi
Kredi Riski	Puanlama Modelleri	Wang vd. 2005	DVM, Bulanık Mantık
Kredi Riski	Puanlama Modelleri	Zhou ve Wang 2012	Rastgele Orman
Kredi Riski	Maruziyet	Bastos 2014	Torbalama
Kredi Riski	Maruziyet	Yeh ve Lien 2009	Bayesyan Ağlar, K-En Yakın Komşuluk, YSA, Karar Ağaçları
Kredi Riski	Maruziyet	Barboza vd. 2017	YSA, DVM, Torbalama, Karar Ağaçları
Kredi Riski	Maruziyet	Raei vd. 2016	YSA
Kredi Riski	Maruziyet	Yang vd. 2011	DVM

Çizelge 2.2 Literatür özetleri (devam)

Risk Türü	Risk Analizi Yöntemi/Aracı	Kaynak	Algoritma
Kredi Riski	Maruziyet	Yao vd. 2017	DVM
Kredi Riski	Puanlama Modelleri	Ala'Raj ve Abbod 2016	YSA, DVM
Kredi Riski	Puanlama Modelleri	Bacham ve Zhao 2017	YSA, Karar Ağaçları
Kredi Riski	Puanlama Modelleri	Cao vd.. 2013	DVM
Kredi Riski	Puanlama Modelleri	Van Gestel vd. 2003	DVM
Kredi Riski	Puanlama Modelleri	Guegan vd. 2018	Elastik Ağlar, Karar Ağaçları, YSA
Kredi Riski	Puanlama Modelleri	Malhotra ve Malhotra 2003	YSA
Kredi Riski	Puanlama Modelleri	Wojcicka 2017	YSA
Kredi Riski	Puanlama Modelleri	Zhang 2017	K-En Yakın Komşuluk, Karar Ağaçları
Kredi Riski	Stres Testi	Blom 2015	Regresyon Analizi
Kredi Riski	Stres Testi	Chan-Lau 2017	Regresyon Analizi
Kredi Riski	Stres Testi	Jacobs 2018	Regresyon Analizi
Kredi Risk	Stres Testi	Islam vd. 2013	Kümeleme Analizi
Kredi Riski	Stres Testi	Pavlenko ve Chernyak 2009	Bayesyan Ağlar
Kredi Riski	Puanlama Modelleri	Brown ve Mues 2012	Gradyan Ağırlıklandırma, Karar Ağaçları, En Küçük Kareler, DVM
Kredi Riski	Risk İzleme	Mainelli ve Yeandle 2006	DVM
Likidite Riski	Risk Limitleri	Gotoh vd. 2014	DVM
Likidite Riski	Risk İzleme	Sala 2011	YSA
Likidite Riski	Puanlama Modelleri	Tavana vd. 2018	YSA, Bayesyan Ağlar

Çizelge 2.2 Literatür özetleri (devam)

Risk Türü	Risk Analizi Yöntemi/Aracı	Kaynak	Algoritma
Piyasa Riski	Risk Altındaki Değer	Zhang vd. 2017	Sınıflandırma, Makine Öğrenmesi
Piyasa Riski	Risk Altındaki Değer	Mahdavi-Damghani ve Roberts 2017	Kümeleme Analizi
Piyasa Riski	Risk Altındaki Değer	Monfared ve Enke 2014	YSA
Piyasa Riski	Risk Altındaki Değer	Kanevski ve Timonin 2010	DVM, Gauss Yöntemi, Kümeleme Analizi
Operasyonel Risk	Risk Değerlendirmesi	Peters vd. 2017	Doğrusal Olmayan Kümeleme Analizi
Operasyonel Risk	Operasyonel Risk Kayıpları	Pun ve Lawryshyn 2012	YSA, K-En Yakın Komşuluk, Bayesyan Ağlar, Karar Ağaçları
Operasyonel Risk	Operasyonel Risk Kayıpları	Sharma ve Choudhury 2016	YSA
Operasyonel Risk analizi	Risk İzleme	Ngai vd. 2011	YSA, Bayesyan Ağlar, Karar Ağaçları
Operasyonel Risk analizi	Risk İzleme	Sudjianto vd. 2010	DVM, Sınıflandırma, Bayesyan Ağlar
Operasyonel Risk	Risk İzleme	Khrestina vd. 2017	Lojistik Regresyon

Çizelge 2.3 Endüstride uygulanan çalışmalar

Amaç	Endüstri Tipi	Referans	Algoritma
Optimal Yatırım Türü Seçiminde Yatırım Stratejisi	Çin Fotovoltaik Endüstrisi	Jing Fu, 2019	Entropi Öğrenme, Analitik Hiyerarşi Süreci
Doğrudan Yatırım Projelerinde Getiri Faktörlerinin Belirlenmesi	Çin Endüstrisi	Qi Chun & Jhon Tang, 2007	Genetik Algoritmalar, Uyumluluk Fonksiyonu
Yolsuzluğun Doğrudan Yatırım Projelerinin Nakit Girişi Üzerindeki Etkisinin Ölçülmesi	Çin,Hindistan, Brezilya, Rusya	Gasanova vd. 2017	Kümeleme Analizi, Kohonen Kendi Kendini Düzenleyen Ağlar
Yatırım Projelerinin Finansal Gelişme ve Ekonomik Büyüme Üzerindeki Etkileri	1980-2009 yılları arasında 78 ülke	Korgaonkar, 2012	Kalite Analizi, Atıf Sınıflandırma

2.3 Makine Öğrenmesi

Makine öğrenmesi, bilgisayar modellerine bir veri kümesinden öğrenme yeteneği sağlayan ve modellerin açık programlama olmadan belirli görevleri yerine getirmesine izin veren istatistiksel teknikleri kullanan yapay zekanın bir alt alanıdır (Domingos 2012). Makine öğrenmesi teknikleri dolandırıcılık tespiti, ödeme işlemleri ve düzenleme gibi çok çeşitli alanlarda finans sektörü genelinde yönetim işlevini iyileştirmek için uygulanmaktadır. Özellikle verilerin yorumlanmasını ve üzerinde hareket edilmesini gerektiren alanlarda çeşitli sorunlara uygulanabilecek bir araç olarak vurgulanmıştır (Awad ve Khanna 2015). Makine öğrenmesi, verilerdeki anlamlı örüntüleri tespit etme yeteneği sunar. Bu sayede veri kümelerinden anlamlı bilgi çıkarma gereksinimi ile karşı karşıya kalan hemen hemen her görev için ortak bir araç haline gelmiştir.

Verilerden anlamlı bilgiler çıkarma gerekliliği ve bunun sonucunda incelenecek örüntülerin karmaşıklığı ile karşı karşıya kalındığında, analist yürütme süreci hakkında açık ve ayrıntılı spesifikasyon sağlayamayabilir. Makine öğrenmesi, analizlere "öğrenme ve uyum sağlama" yeteneği kazandırarak bu zorluğun üstesinden gelir. Makine öğrenmesi, analizleri öğrenir, geliştirir, ele alınması gereken sorunun karmaşıklığına ve uygulama zorluğuna çözüm sağlayabilir (Shalev-Shwartz ve Ben-David 2014).


Yapay zekanın ticari kullanımının ilk yaygın örneklerini, 1960'larda Stanford'da ortaya çıkan (Lindsay 1993) ve 1980'ler ile 1990'larda popülerleşen "uzman sistemler" oluşturur. Uzman sistemler, belirli bir alandaki karmaşık problemleri bir konu uzmanına benzer şekilde çözmek için tasarlanmıştır. Orijinal uzman sistemler LISP ve Prolog gibi dillerde geliştirilen kural tabanlı programlardı. Son yıllarda, klasik uzman sistemlere olan ilgide önemli bir düşüş olmuştur, çünkü bunların yerini yapay zeka içeren sistemler almıştır (Wagner 2017). Yapay zeka sistemleri, insan düşünce süreçlerini taklit eden sistemlerdir (Russell ve Norvig 2009). Bu sistemlerin birçoğu günümüzde bilişsel hesaplama sistemleri olarak tanıtılmaktadır.

Arama motorları ve sürücüsüz otomobillerdeki gelişmeleri yönlendiren makine öğrenimi araçları finans sektörüne uyarlanabilir ve uygulanabilir. Çeşitli teknolojik gelişmeler,

finans sektörünün piyasalar ve tüketiciler hakkında çeşitli yapılandırılmamış finansal veri kümelerini içeren hacimli bir veri altyapısını keşfedebilmesine ve bunlardan yararlanabilmesine katkıda bulunmuştur. Ekonomistler, makine öğreniminin nedenselliği belirleme konusundaki eksikliğine rağmen, karmaşık ilişkileri değerlendirmek için güçlü bir seçenek olması sebebiyle makine öğrenimini giderek daha fazla benimsemektedirler. Veri odaklı ve hesaplama tabanlı makine öğrenimi algoritmaları verilerle ilgili varsayımlara dayanmazlar. Doğrusal olmayan karmaşık ilişkileri ele almada iyi olmakla birlikte, yorumlanmalarının zor olduğu da görülmektedir (Galindo ve Tamayo 2000). Makine öğreniminin benimsenmesi; maliyetlerin azaltılması, verimliliğin artırılması ve risk analizinin iyileştirilmesi gibi potansiyel fırsatları sunar. Ekonomik gereksinimler, yatırım projeleri risk analizinde makine öğrenmesine uyum sağlanması ihtiyacını ortaya koymuştur (Financial Stability Board 2017).


Son yıllarda finansal kurumlardan toplanan veri miktarında ciddi bir artış görülmüştür. Hizmetlerin dijitalleşmesine yönelik büyük bir itici güç ve artan düzenleyici raporlama gereklilikleri, büyük miktarda yapılandırılmamış verinin yüksek bir sıklıkta oluşturulmasına ve/veya toplanmasına neden olmuştur. Bu veriler, tüketici uygulamaları, müşteri etkileşimleri, meta veriler ve diğer harici veri kaynakları dahil olmak üzere çeşitli kaynaklardan gelmektedir. Artan hacimdeki verileri anlama isteği, makine öğrenimi ve yapay zekaya olan ilgiyi arttırmıştır. (Van Liebergen 2017). Makine öğrenimi, finansal hizmetler sektöründe, finansal kuruluşların arzu ettiği analitik kabiliyeti sağlama potansiyeline sahip olarak görülmektedir. Makine öğrenimi, müşteri tercihleri, risk analizi, dolandırıcılık tespiti, davranış izleme, müşteri destek otomasyonu ve hatta biyometri ile birleştirildiğinde finansal kuruluşların iş modellerini doğrudan etkilemektedir.

Makine öğrenimi kullanılarak likidite riski sorununa çözüm sağlayabilir. Likidite riskinin ölçülmesi, faktörler arasındaki bağlantıların incelenmesi gibi temel analizler makine öğrenimi kullanılarak gerçekleştirilebilir. Likidite riskinin tahmin edilmesi amacıyla Yapay Sinir Ağları ve Bayesyan Ağlar literatürde kullanılmakta olan yöntemlerdir.



Şekil 2.1 Yapay sinir ağları

Yapay Sinir Ağları, genel risk eğilimine yaklaşımda ve riski etkileyen faktörlerin belirlenmesinde kullanılabilir. Bir likidite riski olayının gerçekleşme olasılığı Bayesyan Ağlarının uygulanmasıyla tahmin edilebilir. YSA ve Bayesyan Ağlar uygulamaları, sırasıyla fonksiyonel bir yaklaşımla ve dağılımsal bir tahminle riski ölçen en kritik likidite riski faktörlerini ayırt edebilmiştir (Tavana vd. 2018).



Şekil 2.2 Bayesyan ağlar

Van Liebergen (2017), Amerika Birleşik Devletleri Uluslararası Finans Enstitüsü ve teknoloji girişimleriyle yaptığı görüşmeler aracılığıyla finans kurumlarındaki kullanım örneklerini açıklamıştır. Kredi riski modellemesi, kredi kartı dolandırıcılığı ve kara para aklamanın tespit uygulamalarını tartışmışlardır. Ayrıca, makine öğreniminin "örneklem dışı" tahminlerde bulunmaya çalışırken "örneklem içi" korelasyonları öğrendiğini fakat analiz edilen ilişki için bir açıklama sağlamakta yetersiz kaldığını vurgulamıştır. Bu durum, model geliştirme ve değerlendirme konusunda karmaşıklıklar yaratabilmektedir.

Makine öğrenmesi aynı zamanda borsa ve menkul kıymetler piyasasındaki suistimallerin tespit edilmesinde de rol oynamaktadır. Makine öğrenmesi suistimallere karşı denetleyici bir perspektif ve sistemik riskleri gözetilebilme imkanı sunmaktadır. (Bauguess 2015). Hesaplamalı finans alanında makine öğrenimi büyük bir potansiyele sahiptir ve kapsamlı keşifsel veri analizinden modelleme sonuçlarının sunumuna ve görselleştirilmesine kadar çeşitli şekillerde kullanılabilir (Kanevski ve Timonin 2010).


Makine öğrenmesinin bir diğer dezavantajı, iddia edildiği gibi, doğası gereği daha "kara kutu" olmaları ve sonuçların zaman zaman yorumlanmasının zor olmasıdır. Aykırı değerlere karşı hassas oldukları, bunun da verilerin aşırı uyumuna ve sezgisel olmayan tahminlere yol açtığı ileri sürülmektedir. Buna karşılık, açıklayıcı değişkenler ile açıklanan değişkenler arasındaki doğrusal olmayan ilişkilere iyi uyum sağlayabilmeleri, geniş değişken kümeleri ve büyük verilere uygulanabilmesi tahmin doğruluğunu arttırmaktadır (Bacham ve Zhao 2017).

2.3.1 Makine öğrenmesi yaklaşımları


Makine öğrenmesi algoritmalarını eğitmek için üç ana yaklaşım kabul edilmektedir; bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir. Denetimli öğrenme, bir dizi eğitim verisine dayalı olarak girdileri çıktılarla eşleştirir. Algoritma, her bir girdi setini eğitim setindeki beklenen veya etiketlenmiş çıktı ile ilişkilendiren bir fonksiyon çıkarır. Denetimsiz öğrenme, etiketlenmemiş verilerdeki gizli kalıpları bulur ve bunlardan çıkarımlar yapar. Denetimsiz öğrenme modellere girdiler sağlar, ancak beklenen bir sonuç kümesi belirtmez, sonuçlar etiketlenmemiştir. Pekiştirmeli öğrenme,

algoritmaların geçmiş deneyimlerden gelen geri bildirimlere dayanarak deneme yanılma yoluyla öğrenmesini sağlar. Denetimsiz öğrenme gibi, etiketlenmiş veri gerektirmez. Melez bir sistem olan pekiştirmeli öğrenme, modelleri eğitmek için hem etiketli hem de etiketsiz verileri kullanarak denetimli ve denetimsiz öğrenmeyi birleştirir. Bu, sınırlı verinin olduğu veya verileri etiketleme sürecinin önyargılara neden olabileceği durumlarda kullanışlıdır.


Doğrusal Regresyon, Karar Ağaçları ve Yapay Sinir Ağları gibi makine öğrenmesi algoritmaları tahminleme amaçlı kullanılır. Sınıflandırma için ise Lojistik Regresyon, Destek Vektör Makineleri (DVM) veya K-En Yakın Komşular (KNN), En Küçük Kareler (EKK) gibi algoritmaları kullanılarak veriler sınıflandırılır. Öte yandan, denetimsiz öğrenmedeki ana araştırma alanı kümelemedir. Kümeleme, aynı gruba konulan nesnelerin diğer gruplardaki nesnelere göre birbirlerine daha çok benzeyeceği şekilde nesneleri bir araya getirmeyi amaçlar.



Şekil 2.3 En küçük kareler yöntemi



Şekil 2.4 K-en yakın komşuluk yöntemi



Şekil 2.5 Destek vektör makineleri yöntemi

2.4 Derin Öğrenme Yöntemleri

Yapay sinir ağları, makine öğreniminin geliştirilmesinde kilit bir teknoloji haline gelmiştir. İlk olarak 75 yıl önce insan beyninin işleyişinden esinlenerek önerilmişlerdir (McCulloch ve Pitts, 1943). Diğerlerinin yanı sıra, Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN) ve özyinelemeli sinir ağları dahil olmak üzere bir dizi farklı yapay sinir ağı sınıfı vardır. CNN görüntü sınıflandırma ve video işleme gibi işler için idealdir çünkü görüntü parçalarına odaklanarak kalıpları belirleyebilirler. RNN'ler konuşma ya da metin analizi gibi konularla uğraşmak için daha iyidir çünkü bir sonraki ayın rakamını tahmin etmek için aylık hisse senedi fiyat rakamları gibi zaman serisi bilgilerini kullanırlar. Çekişmeli Üretici Ağ (GAN) ilk kez 2014 yılında tanıtıldıklarından bu yana son yıllarda büyük ilgi görmüştür (Goodfellow, 2014). GAN'lar birbiriyle rekabet eden iki sinir ağından oluşur. Sinir ağlarından biri eğitim veri setine benzer veriler üretir, diğeri ise verilerin eğitim veri setinden mi yoksa üretici ağ tarafından mı üretildiğini değerlendirmeye çalışır.

Sinir ağlarının yanı sıra diğer iyi bilinen makine öğrenimi algoritmaları arasında DVM'ler, KNN ve diğerleri bulunur. Sınıflandırma ve regresyon analizi için kullanılan DVM'ler, n boyutlu bir uzayda bir dizi veri noktası arasındaki mesafeyi en aza indiren bir hiper düzlem bulmayı içerir. Bayesyan ağları olasılık dağılımlarından oluşturulur ve

tahmin ve anormallik tespiti için olasılık yasalarını kullanır. KNN, eğitim verilerindeki en benzer veri noktalarını seçer, bu da algoritmanın gelecekteki veri girdilerini aynı şekilde sınıflandırmasını sağlar. Bazı teknikler belirli görevler için diğerlerine göre daha uygundur. Bu araştırma kısmen bu bilgi alanına katkıda bulunmayı amaçlamaktadır. Gelecekteki uygulamalarda ve çalışmalarda belirli görevler için uygun algoritmaların seçilmesine yardımcı olmak için belirli algoritmaların etkinliğini değerlendirmek önemlidir.

DVM denetimli bir makine öğrenimi algoritmasıdır ve sınıflandırma problemlerinde yaygın olarak kullanılmasına rağmen kredi puanlama için nispeten yenidir. Bu algortmada, her veri ögesi n boyutlu uzayda bir nokta olarak çizilir, her özelliğin değeri belirli bir koordinatın değeridir (n -özellik sayısıdır). Sınıflandırma, iki sınıfı ayıran sınır olan hiper düzlemin bulunmasıyla gerçekleştirilir (Ray 2015). DVM, kredi riski değerlendirme ve kredi puanlama modelleri tasarlamak için olduğu gibi veya çeşitli biçimlerde uygulanmıştır (Bellotti ve Crook 2009; Cao vd. 2013; Van Gestel vd. 2003; Huang vd. 2007; Lai vd. 2006). Harris (2013) DVM tabanlı kredi skorlama modellerini geniş (vadesi 90 günden az geçmiş) ve dar (vadesi 90 günden fazla geçmiş) olarak karşılaştırmıştır. Daha geniş bir tanım kullanılarak oluşturulan modellerin daha doğru olduğu ve tahmin doğruluğunda iyileşmelere izin verdiği bulunmuştur.

Destek Vektör Makineleri, temerrüde düşen kredi kartı müşterilerini sınıflandırmada başarılıdır. Ayrıca, test edildiklerinde ve geleneksel tekniklerle karşılaştırıldıklarında temerrüt riskini belirlemede en önemli olan özellikleri keşfetmede rekabetçi oldukları bulunmuştur (Bellotti ve Crook 2009). Sınıflandırıcı algoritmaların, kredi puanlamasında standart lojistik regresyondan önemli ölçüde daha doğru performans gösterdiği bulunmuştur. Ayrıca, yapay sinir ağları gibi gelişmiş yöntemlerin kredi skorlama veri setlerinde son derece iyi performans gösterdiği ve aşırı öğrenme makinesinden daha iyi performans gösterdiği görülmüştür (Lessmann vd. 2015). Yatırım projelerinde önemli bir sorun olan müşterilerin doğru sınıflandırılması ve kredi riskinin tahmin edilmesi için sürekli olarak yöntemler ve modeller geliştirilmektedir. Bu yöntemlerde uygulanan çeşitli yaklaşımlar, daha büyük ve karlı bir kredi portföyüne yol açabilecek kredibilite tahminlerinin doğruluğunu artırmayı amaçlamaktadır. Sinir ağlarının kredi riski karar

sürecinde önemli bir değere sahip olduğu kanıtlanmış ve şirket sıkıntı tahminlerindeki uygulamalarının kredi riski değerlendirmesinde faydalı olduğu bildirilmiştir (Wójcicka 2017).

Kredi riski, makine öğreniminin uygulanması için en çok araştırılan ve değerlendirilen risk alanı olsa da, bu yeni bir olgu değildir. Geçmiş 1994 yılına kadar uzanan Altman ve diğerleri, geleneksel istatistiksel sıkıntı ve iflas tahmin yöntemlerini alternatif sinir ağı algoritmasıyla karşılaştıran bir analiz gerçekleştirmiş ve ikisinin bir arada kullanıldığı bir yaklaşımın doğruluğu önemli ölçüde artırdığı sonucuna varmıştır (Aziz ve Dowling 2018). Hand ve Henley (1997), "kredi puanlamasının, kredi başvurusunda bulunanları "iyi" ve "kötü" risk sınıflarına ayırmak için kullanılan resmi istatistiksel yöntemleri tanımlamak için kullanılan bir terim olduğunu" savunmuştur. Kredi skorlama modelleri, bireylerin veya şirketlerin temerrüt riskini tahmin etmek için ekonomik ve finansal göstergelere uygulanan çok değişkenli istatistiksel modellerdir. Bu göstergelere tahminlerdeki önemine göre bir ağırlık atanır ve bir kredi itibarı endeksine ulaşmak için girdi olarak beslenir. Bu sayısal puan, borçlunun temerrüde düşme olasılığının bir ölçüsü olarak hizmet eder. Destek vektör makinesi tekniğinin kredi riski değerlendirmelerinde en yaygın olarak uygulanan teknik olduğu sonucuna varılmıştır. Özellik alt kümesinde azaltma yöntemleri ekleyerek performansı artırmak için hibrit DVM modelleri önerilmiştir.

Bazı makaleler ise makine öğrenimi algoritmalarının uygulanmasındaki verimliliği vurgulamak için geleneksel istatistiksel yöntemlerle karşılaştırmışlardır. Galindo ve Tamayo (2000), istatistiksel ve makine öğrenimi sınıflandırma tekniklerinin karşılaştırmalı bir analizi yoluyla, bireysel riskin doğru tahminlerini bulmak için kurumların kredi portföylerini araştırmıştır. Çalışmanın bir parçası olarak 9000'den fazla model oluşturmuşlar ve çeşitli algoritmaların performansını sıralamışlardır. CART karar ağacı modellerinin temerrüt için en iyi tahminleri sağladığını, sinir ağlarının ise ikinci sırada geldiğini göstermişlerdir. Hamori ve diğerleri (2018), temerrüt ödeme verilerini analiz ederken tahmin doğruluğunu ve torbalama, rastgele orman, boosting ile sinir ağı yöntemlerinin sınıflandırma kabiliyetini incelemiş ve karşılaştırmıştır. Çalışılan makine öğrenimi yöntemleri arasında boosting'in üstün olduğunu bulmuşlardır. Bir dizi

araştırmacı da kredi puanlamasını incelemek için hibrit tekniklerin ve topluluk yöntemlerinin uygulanmasını değerlendirmiştir (Bastos 2014; Hamori vd. 2018; Raei vd. 2016).

Kredi puanlama sorunlarıyla başa çıkmada, düzenlenmiş lojistik regresyon kullanan topluluk öğrenmesi uygulanmıştır. Verileri dengelemek ve çeşitlendirmek için kümeleme ve torbalama algoritmaları uygulayan bir yöntemin ve ardından kredi risklerini değerlendirmek için lasso-lojistik regresyon topluluğunun birçok popüler kredi puanlama modelinden daha iyi performans gösterdiği bulunmuştur (Wang vd. 2015). Khandani ve diğerleri (2010), kredi kartı sahiplerinin temerrüt ve gecikme durumlarının sınıflandırma oranlarını iyileştirmek için doğrusal olmayan, parametrik olmayan bir tahmin modeli oluşturmuştur. Tüketici kredisi risk modeli, büyük veri kümelerindeki ince doğrusal olmayan ilişkileri tanımlayabilmiştir. Bu ilişkilerin logit, diskriminant analizi veya kredi skorları gibi standart tüketici kredisi-temerrüt modelleri kullanıldığında tespit edilmesinin tipik olarak zor olduğu bildirilmiştir. Bu, kredi hattı Risk analizine, toplam tüketici kredisi temerrütlerinin tahminine ve tüketici kredisi döngüsünün tahminine olanak tanır. Yu ve diğerleri (2016), kredi riski değerlendirmesi için umut verici bir araç olarak yeni bir çok aşamalı derin inanç ağı tabanlı aşırı makine öğrenimi önermektedir. Üç aşamada çalışan çok aşamalı topluluk öğrenme paradigmaları çerçevesinin, yüksek tahmin doğruluğu ile tipik tek sınıflandırma tekniklerinden ve benzer çok aşamalı topluluk öğrenme paradigmalarından daha iyi performans gösterdiği gösterilmiştir.

Wang ve diğerleri (2005) yeni bir bulanık destek vektör makinesi önermektedir. Algoritma, bulanık DVM'nin aykırı değerlere karşı duyarsız olma özelliğini korurken, daha fazla genelleme yoluyla iyi alacaklıları kötü olanlardan ayırmayı amaçlamaktadır. Kredi analizinde umut verici uygulama sonuçları gösteren iki taraflı ağırlıklı bir bulanık DVM sunmuşlardır. Huang ve diğerleri (2007), üç strateji kullanılarak oluşturulan hibrit bir DVM'ye dayalı girdi özelliklerinden bir başvuru sahibinin kredi puanını değerlendirmek için bir kredi puanlama modeli oluşturmuştur. Yeh ve Lien (2009), makalelerinde, temerrüt olasılığının tahmin edilmesinin, uygulayıcıların ve araştırmacıların karşılaştığı bir zorluktur ve daha fazla çalışmaya ihtiyaç duymaktadır.

Birkaç makale, temerrüt olasılığını veya iyileşme oranlarını tahmin etmek için sadece sınıflandırmanın ötesine geçmeyi amaçlamaktadır (Bastos 2014; Raei ve ark. 2016).

Raei ve diğerleri (2016), ticari bir bankadaki kurumsal müşterilerin temerrüde düşme olasılığını tahmin etmek için yeni bir hibrit model araştırmıştır. Hibrit modeli, sinir ağlarının 'kara kutu' -parametreler açısından anlaşılabilir olmayan model- eleştirisini ele alabilecek bir model olarak sunmaktadırlar. Araştırma iki aşamalı bir yaklaşımı, yani logit modellerin anlaşılabilirliği ile sinir ağları gibi doğrusal olmayan tekniklerin tahmin gücünü birleştirmektedir. Bu hibrit modelin genel doğruluğunun her iki temel modelden de daha iyi performans gösterdiği görülmüştür. Düşük temerrütlü portföyler çok düşük riskli olarak kabul edilen portföylerdir. Bu portföylerde sınıf dengesizliği sorunu vardır, çünkü temerrüde düşenler bir sınıfta, iyi ödeme yapanlardan oluşan bir sınıftan daha az sayıda bulunurlar. Gradient boosting ve rastgele orman sınıflandırıcılarının sınıf dengesizliği sorunu sergileyen örneklerle başa çıkmada iyi performans gösterdiği bulunmuştur (Brown ve Mues 2012).

Yatırım projeleri, karşı tarafın temerrüde düşme olasılığını değerlendirebilecek verimli modeller geliştirmeyi amaçlamaktadır. Barboza ve diğerleri (2017) iflasın bir yıl öncesinden tahmin edilmesi için makine öğrenimi modellerini test etmiş ve performansı geleneksel yöntemlerden elde edilen sonuçlarla karşılaştırmıştır. Önemli tahmin doğruluğuna ulaşıldığını bildirmişler ve ayrıca makine öğrenimi tekniklerinin geleneksel mekanizmalara kıyasla önemli sınıflandırma doğruluğu için kolayca uygulanabileceğini öne sürmüşlerdir. Modelin açıklama kabiliyetine ilişkin endişelere rağmen, iflas modellerinin karmaşıklığı göz önüne alındığında, makine öğrenimi önemli bir yardımcı olabilir. Yang ve diğerleri (2011) de iflası tahmin etmek için yeni bir yöntem araştırmış ve bilgi füzyonu için DVM ile kısmi en küçük kareler tabanlı özellik seçiminin birleşik bir yöntemini önermiştir. Bir banka, modelin tahmin sürecinde en alakalı finansal göstergeleri seçme kabiliyetinden ve ayrıca yüksek tahmin doğruluğu seviyesinden faydalanabilir. Kredi riski analizinde stres testi alanını araştıran birkaç makale de bulunmaktadır (Islam vd. 2013). Stres testi, aşırı senaryoların bir banka üzerindeki etkisini belirlemek için makro-ekonomik gelişmeler ile bankacılık değişkenleri arasındaki bağlantının modellenmesini gerektirir. Daha sık olarak, gelecekteki

kar/zararlara ilişkin tahminlerin çoğunlukla ayrıştırılmış portföy seviyelerinde yapıldığı, veri yoğun ve kayıpların kesin nedenlerini belirlemeyi zorlaştıran aşağıdan yukarıya yaklaşımlar kullanılır. Yukarıdan aşağıya bir yöntem kullanılarak toplu bir portföy üzerinde yapılan tahminler bu süreci tamamlayabilir. Önceden belirlenmiş bir modele ihtiyaç duymayan bir denetimli öğrenme algoritması En Küçük Mutlak Küçültme ve Seçim Operatörü (Lasso) yöntemidir. Lasso'nun daha kapsamlı bir versiyonu, çekici yakınsama özelliklerine sahip olan Adaptif Lasso'dur. Uyarlanabilir Kement, yukarıdan aşağıya stres testinde olduğu gibi teorik modellerin yokluğunda, binlerce olası spesifikasyondan oluşan bir dizi arasından en uygun yukarıdan aşağıya modeli keşfetmek için kullanılabilir. Kredi kayıp oranlarının davranışını en iyi tanımlayan değişkenleri arayarak seyrek, yaklaşık olarak yansız çözümler verdiği ve makro-ekonomi ile kredi kayıp oranları arasındaki ilişkinin basit bir tanımıyla sonuçlandığı gösterilmiştir.

Önemli bir sorun, bir modeli eğitmek için önemli miktarda veriye ihtiyaç duyulmasıdır (Blom 2015). Stres senaryoları daha kapsamlı hale geldikçe ve giderek artan sayıda birincil değişkeni kapsadıkça model seçimi ve tahmini zorlaşmaktadır. Veriler arasındaki paternleri ve ilişkileri belirlemeye yönelik makine öğrenimi teknikleri model seçimini ve tahmini kolaylaştırabilir. Bu teknikler stres testlerinde yaygın olarak uygulanmıyor gibi görünmektedir. Çok sayıda potansiyel ortak değişken olduğunda ve gözlem sayısı az olduğunda, kement regresyonlarının tahmin modelleri oluşturmak için uygun olduğu bulunmuştur. Uygulamalı stres testlerinde gerekli olan performans göstergelerinin tahmininde geleneksel istatistiksel modellerden daha iyi performans göstermeleri muhtemeldir. Lasso tipi tahmincilerin bir avantajı da stres testlerinin yüksek boyutlu doğasından kaynaklanan komplikasyonlarla başa çıkabilmeleridir (Chan-Lau 2017). Bir makine öğrenimi tekniği olan Çok Değişkenli Uyarlanabilir Regresyon Splines (MARS), sınıflandırma ve regresyon ağacı (CART) yönteminin aşamalı doğrusal regresyonunun bir genellemesi olarak görülebilir. Vektör Otoregresyon (VAR) gibi istatistiksel regresyon modellerinin stres testi, şişman kuyruklu dağılımlar olgusunu açıklayamadığı bilinen yaygın bir modelleme yaklaşımıdır. Bu modellerin ampirik bir testi, MARS modelinin model testinde daha yüksek doğruluk ve üstün örneklem dışı performans sergilediğini ve MARS'ın daha makul tahminler ürettiğini ortaya koymuştur (Jacobs 2018). Olasılıksal grafikler, riskin daha iyi anlaşılmasını sağlayan ağaçla güçlendirilmiş

bir Bayes ağı ile kredi yoğunlaşma riskinin modellenmesi ve değerlendirilmesi için kullanılabilir. Bunun aynı zamanda, borçlunun finansal durumundaki değişikliklere bağlı olarak kayıp riski tahminleri sağlama kabiliyeti ile stres testi analizleri için de uygun olduğu görülmüştür (Pavlenko ve Chernyak 2009). Belirli makine öğrenimi algoritmaları ve gelişmiş görselleştirme araçları, çoklu deneyler gerçekleştirmek ve sonuçları analiz etmek için kullanılır, olası belirsizlikleri keşfetme ve girdilere dayalı nedenleri belirleme yeteneği sağlar.

Zhang ve diğerleri (2017), piyasa riskini ölçmek için Genelleştirilmiş Otoregresif Koşullu Dalgalanmaya dayalı bir model önermektedir. Heteroskedastik (GARCH) modeli ve oynaklığı tahmin etmek için Extreme Machine Learning (ELM) algoritması. Model, GELM-RBF kullanarak hedef zaman serilerinin volatilitelerini tahmin eder ve tahmin edilen volatilitelerin ekstrapolasyonu, doğruluk ve verimlilik açısından geliştirilmiş performansla VaR'ın hesaplanmasına olanak tanır. Modeli, tahmin için gauss olasılığı gerektirmeyen ve doğrusal olmayan bir veri sürücü modeli olan stokastik bir eşleme yöntemi kullanmaktadır. Bayesian algoritmaları, k-en yakın komşu, destek vektör makineleri ve karar ağacına dayalı torbalama topluluğu sınıflandırıcısı dolandırıcılık tespit sistemlerinde çeşitli şekillerde kullanılmıştır. Karşılaştırmalı bir değerlendirme, karar ağacı algoritmalarına dayalı torbalama topluluğu sınıflandırıcısının, öznelik değerlerinden bağımsız olduğu ve sınıf dengesizliğini de ele alabildiği için iyi çalıştığını göstermiştir (Zareapoor ve Shamsolmoali 2015).

Risk modellemesi söz konusu olduğunda makine öğrenmesi yaklaşımının kantitatif ticaret uygulamalarında istatistiksel risk modellerinden daha iyi performans gösterdiğini ortaya koymuşlardır (Kakushadze ve Yu, 2019). Makine öğreniminin orta boyuttaki zor riskten korunma problemlerini çözmede diğer mevcut algoritmalar kadar etkili olabileceğini göstermektedir. Riskten korunma stratejilerini hesaplamak için değiştirilmiş bir LSTM sinir ağı gibi teknikler kullanmışlardır (Fecamp vd. 2019). Sardelich ve Manandhar haber ve fiyat verilerini kullanarak günlük hisse senedi volatilitelerini tahmin etmeye çalışmışlardır. Çift Yönlü Uzun Kısa Dönem Hafıza Sinir Ağı ve LSTM'ler kullanarak modelleri, analiz edilen tüm sektörlerde (finans, sağlık vb.) iyi bilinen GARCH modelinden daha iyi performans göstermişlerdir. Kara listeye eklenmesi

muhtemel firmaların tahmin performansını iyileştirmek için 35.657 küresel firmadan oluşan heterojen bir bilgi ağından yararlanmışlardır (Hisano vd., 2018). Kara listeler, finansal veya çevresel sorunlar gibi kabul edilemez sorunları olan kuruluşları takip etmek için kullanılır. Geliştirdikleri model, otuz gizli birime sahip basit bir MLP'den oluşmaktadır.

Zhang ve diğerleri (2018) CNN ve doğal dil işleme kullanarak Çinli şirketlerin kurumsal kredibilitesini tahmin etmişlerdir. Haber makalelerinin metnini özetlemek ve her konudan en önemli kelimeleri çıkarmak için bir CNN kullanmışlardır. CNN, haber makalelerinin bir şirketin güvenilirliğini nasıl yansıtabileceğini makalelerin üslubu ve kelime geçişleri aracılığıyla öğrenmektedir. Modellerinin çalıştığını, negatif bir derecelendirme sistemi oluşturarak ve modellerinin sonuçları ile negatif derecelendirme arasında bir korelasyon göstererek doğrulamışlardır

Literatür ve değerlendirme raporları incelendiğinde, bu tür değerlerin değerlendirilmesinin, özellikle oksijen üretimi gibi enerji yatırım projeleri için anlamlı bir karar için yeterli bilgi sağlamadığı görülmektedir. Derin öğrenme algoritmaları, risk veya yatırım alanında kapsamlı bir şekilde incelenmiştir. Yatırımcıların yatırım stratejisini ve getiri oranını iyileştirmek için Xie ve Liu, derin öğrenmenin finansal veri işleme ve yatırım modellerinin yanı sıra yatırım planı oluşturmada kullanımını incelemiş ve tartışmıştır. Sohangir ve diğerleri tarafından finansal tahmin için en etkili modelin evrimsel sinir ağı (CNN) olduğu gösterilmiştir. Başka bir araştırma, finansal risk tahminlerinin doğruluğunun ve yatırım portföylerinin optimizasyonunun kritik olduğunu tespit etmiş, bu nedenle sınıflandırmada uzun kısa süreli bellek (LSTM) ve tekrarlayan sinir ağının (RNN) performansını karşılaştırmıştır; sonuçlar LSTM'nin daha iyi bir performansa sahip olduğunu ve bunun yatırım karlarını maksimize etmek için büyük önem taşıdığını göstermiştir. Mevcut çalışmalara dayanarak, bu makale, yatırım projeleri için bir risk değerlendirme modeli oluşturmak ve yatırım risklerini bilimsel ve etkili bir şekilde analiz etmek için özel bir RNN tekniği olan LSTM'yi ve derin öğrenme teknikleri olarak CNN'i kullanmayı önermektedir. Bu derin öğrenme tekniklerini kullanarak, işletmelerin yatırım risklerini belirleyebileceği ve azaltabileceği yatırım projelerinin risk analizini değerlendireceğiz.

2.4.1 Evrişimli sinir ağıları (CNN)

CNN, 1998 yılında Lecun ve arkadaşları tarafından önerilen bir ağ modelidir (Lecun vd. 1998) Evrişimsel sinir ağıları (CNN'ler) bir tür çok katmanlı algılayıcıdır (MLP). İleriye dönük bir sinir ağı olan CNN, hayvanların görsel merkezinden ilham almıştır. CNN, görüntü işleme ve doğal dil işlemede iyi bir performansa sahiptir (Kim&Kim, 2019). Zaman serilerinin tahmininde etkili bir şekilde uygulanabilir. CNN'nin yerel algılama ve ağırlık paylaşımı, parametre sayısını büyük ölçüde azaltarak model öğreniminin verimliliğini artırabilir (Qin vd. 2018). Buradaki matematiksel evrişim süreci, bir nöronun uyarıcı alanından uyarıcılara tepkisi olarak düşünülebilir. Tüm CNN katmanları tamamen birbirine bağlanacak şekilde tasarlanmıştır ve her bir evrişim filtresi öğrenilecek özellikleri oluşturur. CNN'nin yerel algılama ve ağırlık paylaşımı, parametre sayısını büyük ölçüde azaltarak model öğreniminin verimliliğini artırabilir. CNN temel olarak iki bölümden oluşur: konvolüsyon katmanı ve havuzlama katmanı. Her konvolüsyon katmanı birden fazla konvolüsyon çekirdeği içerir ve hesaplama formülü aşağıda gösterilmiştir.

$$I_t = \tanh(x_t * k_t + b_t) \quad (7)$$

Burada;

I_t : Konvolüsyon sonrası çıktı değeri

$\tanh$: Aktivasyon fonksiyonu

x_t : Girdi vektörü

k_t : Konvolüsyon çekirdeğinin ağırlığı

b_t : Konvolüsyon çekirdeği önyargısı


olmak üzere konvolüsyon katmanında verilerin özellikleri çıkarılır. Ancak çıkarılan özellik boyutları çok yüksek olduğundan hem ağın eğitim maliyetini azaltmak hem öğrenimi kolaylaştırmak için konvolüsyon katmanından sonra havuzlama katmanı eklenir. CNN katmanları katlamalıdır. Bu katlamalı katmanlar, havuzlama yoluyla hem ebatla hem de eğitim süresinde optimizasyon sağlar.

Bu katmanlar temel bazda konvolüsyonel ve havuzlama katmanları içinde daha özel olarak şu şekilde ayrılırlar.


- Konvolüsyonel Katman : Özellikleri belirlemek amacıyla kullanılır.
- Lineer Olmayanın Belirlenmesi Katmanı : Sisteme lineer olmayanlığın (nonlinearity) belirtilmesi için kullanılır.
- Havuzlama Katmanı: Ağırlık sayısını ve özellik boyutlarını düşürür. Uygunluğu kontrol eder.
- Düzleştirme Katmanı : Klasik sinir ağı için verileri hazır hale getirir.
- Tam Bağlı Katman : Sınıflamada işleme alınan standart sinir ağıdır.

Temel olarak, CNN, sınıflandırma probleminin çözüm yolu için standart sinir ağı kullanır ve bilgileri tespit etmek ve bazı özellik durumlarını belirlemek için diğer katmanları kullanır.

CNN'e özellik olarak tanımlanacak nitelik vektörünün oluşturulması Şekil 2.6'daki gibidir.




Şekil 2.6 CNN nitelik vektörü oluşturulması



Şekil 2.7 CNN modeli genel görünüm

Şekilde Evrişimli Sinirsel Ağlar gösterimi verilmektedir. A. Evrişim katmanında, a ile temsil edilen giriş yamasının alanları, tabloda farklı renk blokları olarak belirtilen matrislerle (k ile temsil edilen evrişim çekirdeği) çarpılır. B. Havuzlama tabakasında, evrişimin sonuçları özetlenir. Burada maksimum havuzlama örnek olarak alınır. a_{ij} , c_{ij} , k_{ij} karşılık gelen matristeki i satırında ve j sütununda bulunan sayıyı temsil eder.




Şekil 2.8 CNN modelinin matris gösterimi

2.4.2 Uzun kısa zamanlı hafıza (LSTM)

LSTM ağı, sıralı veri analizi için özel olarak tasarlanmış farklı bir derin öğrenme ağıdır. LSTM ağlarının avantajı, ağıdaki hem kısa hem de uzun vadeli değerlerin hatırlanabilmesidir. Bu nedenle, LSTM ağları çoğunlukla derin öğrenme araştırmacıları tarafından otomatik konuşma tanıma, dil çevirisi, el yazısı karakter tanıma, zaman serisi veri tahmini gibi sıralı veri analizi için kullanılır. LSTM ağları LSTM birimlerinden oluşur. LSTM birimi giriş, çıkış ve unut kapılarına sahip hücrelerden oluşur. Bu üç kapı

bilgi akışını düzenler. Bu özelliklerle, her hücre keyfi zaman aralıklarıyla istenen değerleri hatırlar. LSTM hücreleri sinir ağlarının katmanlarını oluşturmak için birleşir. Şekilde, temel LSTM birimini göstermektedir (σ : sigmoid fonksiyonu, $\tanh$: hiperbolik tanjant fonksiyonu, $\times$: çarpma, $+$: ekleme)



Şekil 2.9 LSTM modeli


2.4.3 Tekrarlayan sinir ağı (RNN)

Tekrarlayan sinir ağı (RNN), önceki adımdan gelen çıkışın mevcut aşamaya girdi olarak beslendiği bir tür sinir ağıdır. RNN, kelimeleri hatırlama gereği nedeniyle önerilmektedir. Bu sorun gizli katman yardımı ile çözülür. RNN'in en önemli özelliği, bir dizi hakkında bazı bilgileri hatırlayan gizli durumdur. RNN, hesaplananlarla ilgili tüm bilgileri hatırlayan bir belleğe sahiptir. RNN, diğer sinir ağlarından farklı olarak, parametrelerin karmaşıklığını azaltır. Çıktıyı üretmek için tüm girdilerde veya gizli katmanlarda aynı görevi gerçekleştirir. Her giriş için aynı parametreleri kullanmak, parametrelerin karmaşıklığını azaltır.

Literatürde, RNN zaman serisi verileri, ses ve konuşma verileri, dil gibi ardışık veriler üzerinde kullanılmıştır. Art arda yapılandırılmış RNN birimlerinden oluşur. İleri besleme ağlarının aksine, RNN'ler gelen girişleri işlemek için dahili belleği kullanır. RNN'ler, çeşitli alanlarda (el yazısı tanıma, konuşma tanıma vb.) Zaman serisi verilerinin analizinde kullanılır.


Farklı RNN yapı tipleri vardır: bire çok, çoktan bire, çoktan çoğa. Genellikle, RNN çalışma sırasında giriş dizisi serisini tek tek işler. Gizli katmandaki birimler, durum vektörü"ndeki girişin geçmişi hakkında bilgi içerir. RNN'ler Zaman İçinde Geri Yayılım (BPTT) yöntemi kullanılarak eğitilebilir. BPTT kullanıldığında, herhangi bir zamanda kaybın farklılaşması, ağıın önceki zamandaki ağırlıklarını yansıtmıştır. RNN'lerin eğitimi, İleri Beslemeli Sinir Ağları'ndan daha zordur ve RNN'lerin eğitim süresi daha uzun sürer.

Basit RNN




Şekil 2.10 Basit RNN modeli yapısı

Kompleks RNN



Şekil 2.11 Kompleks RNN modeli genel yapısı



Şekil 2.12 RNN modeli vektör ve matris dönüşümleri


Şekilde Recurrent Neural Network (Özyinelemeli Sinirsel Ağlar) Gösterimi verilmiştir. A. Ortak sinir ağlarının (üst) ve şemanın (alt) açılım şekli. B. Tekrarlayan sinir ağlarının (üstte) ve açılma şekillerinde (altta) bir örnek. Kırmızı kare bir kez adım gecikmesini temsil eder. Panel A'dan farklı olarak, panel B'deki oklar bağlantı kümelerini temsil eder. W ve B, sırasıyla ağırlık matrisi ve bias vektörünü temsil eder. x ve y sırasıyla ağın giriş ve çıkışını temsil eder; h, ağın gizli birimlerini gösterir; L, yoğun şekilde bağlanmış katmanlar veya bırakma katmanları gibi dönüşüm çiftlerinden oluşur; U, iki komşu zaman noktası arasındaki dönüşümü gösterir; ve t zaman noktasını temsil eder.

2.4.4 CNN - LSTM modeli

CNN, görsel alan boyunca öne çıkan unsurlara odaklanmasıyla ayırt edilir ve bu da onu özellik mühendisliğinde yaygın olarak kullanılır hale getirir. LSTM, zamansal dizilere

göre genişleme yeteneğine sahiptir ve zaman serisi analizinde yaygın olarak kullanılmaktadır. CNN ve LSTM'nin özelliklerine dayanarak yatırım projelerinde en önemli risk ölçütü olan fiyat unsuru için tahmin modeli oluşturulmuştur. Giriş katmanı, tek boyutlu konvolüsyon katmanı, havuzlama katmanı, LSTM gizli katmanı ve tam bağlı katman dahil olmak üzere CNN ve LSTM bileşenlerinden oluşan bir makine öğrenmesi modeli geliştirilmiştir. CNN, Lecun ve arkadaşları tarafından 1998 yılında tanıtılan bir modeldir. CNN, görüntü işleme ve doğal dil işlemede güçlü etkinlik gösteren bir tür ileri beslemeli sinir ağıdır. Zaman serisi tahmini için verimli bir şekilde kullanılabilir. CNN'in yerel algısı ve ağırlık paylaşımı, parametre sayısını önemli ölçüde azaltarak model öğrenme verimliliğini artırır. CNN temel olarak iki bileşenden oluşur: konvolüsyonel katman ve havuzlama katmanı. Her bir evrimsel katman birçok evrimsel çekirdekten oluşur ve hesaplama algoritması denkleminde (1) sunulmuştur. Konvolüsyon katmanındaki konvolüsyon işleminin ardından verinin özellikleri çıkarılır; ancak bu özelliklerin boyutluluğu aşırı yüksektir. Bu sorunu çözmek ve ağırlık eğitimi maliyetlerini azaltmak için, özellik boyutlarını azaltmak amacıyla konvolüsyon katmanından sonra bir havuzlama katmanı eklenmiştir.

LSTM, 1997 yılında Schmidhuber ve arkadaşları tarafından tanıtılan bir ağ mimarisidir. LSTM, RNN'lerdeki gradyan genişlemesi ve gradyan kaybolması gibi kalıcı sorunları ele almak için geliştirilmiş bir ağ mimarisidir. Doğal hafızası ve çok hassas tahmin kapasitesi nedeniyle konuşma tanıma, duygu analizi ve metin analizinde yaygın olarak kullanılmıştır. Son zamanlarda, RNN'lerde gradyan genişlemesi ve gradyan kaybolması gibi kalıcı sorunları ele almak için borsa tahmininde kullanılmıştır. Doğal hafızası ve çok hassas tahmin kapasitesi nedeniyle konuşma tanıma, duygu analizi ve metin analizinde yaygın olarak kullanılmaktadır. Son yıllarda borsa tahminlerinde, yatırım tahminlerinde ve risk yönetiminde kullanılmaktadır.



Şekil 2.13 CNN-LSTM mimarisi

Literatürden de anlaşılacağı üzere; CNN ve LSTM modelleri, yatırım projelerinin risk analizine ilişkin değerlendirme ve tahmin eğitimlerinde kullanılabilmektedir. Gradyan kaybolma probleminin çözümü söz konusu olduğunda, yalnızca özel bir tekrarlayan sinir ağı olan LSTM algoritması, aynı anda birkaç orijinal veri girdisini işleyebilir ve bunların zaman içindeki ilişkilerini dikkate alabilir. Gelecekte, gizli katmanındaki bilgiler ya çıktı ucuna ya da gizli katmanın kendisine iletilebilir. Ayrıca, LSTM algoritmasının ağırlığı, gradyan genişlemesini veya kaybolmasını en aza indirmek için sürekli olarak güncellenebilir. LSTM, uzun süreli bir belleğe sahip olması ve uygulanmasının kolay olması nedeniyle avantajlara sahiptir; uzun dizi eğitimi sırasında ortaya çıkan gradyan kaybolması ve gradyan patlaması sorunları ele alınmaktadır. LSTM algoritması eğitimi dört aşamadan oluşmaktadır:

Adım 1: LSTM gizli katmanının çıktısını hesaplayın. w , o_t , c ve f sırasıyla çıkış kapısı, hücre durumu, unutma kapısı ve giriş kapısını, b ofseti, w ağırlık katsayısı matrisini ve T ($\tan h$) ve S (*sigmoid*) aktivasyon fonksiyonlarını gösterebilir; ardından unutma kapısı ve giriş katmanı ifadeleri aşağıdaki üç denklemde (8),(9) ve (10) gösterilmiştir.

$$f_t = \sigma(w_f[h_t - 1, x_t] + b), \quad f_t \in [0,1] \quad (8)$$

$$i_t = \sigma(w_i[h_t - 1, x_t] + b_i) \quad (9)$$

$$cl_t = \tanh(w_c[h_t - 1, x_t] + b_c) \quad (10)$$

Hücre durumunu güncelleyin.

$$c_t = f_t * c_{t-1} + i_t * cl_t \quad (11)$$

Model çıktısı, fonksiyonun etkinleştirilmesiyle elde edilir:

$$o_t = \sigma(w_o[h_t - 1, x_t] + b) \quad (12)$$

$$h_t = o_t * \tanh(c_t) \quad (13)$$

Adım 2: Her bir LSTM hücresinin δ hatası, zaman ve ağ seviyesindeki hata terimleri de dahil olmak üzere geri yayılım ile hesaplanır. δ_t , t zamanındaki hata terimini, ve δ_k k zamanındaki hata terimini gösterebilir; hata teriminin iletimini tersine çeviren gecikme şu şekilde ifade edilir:

$$\delta_t^T = \frac{\partial E}{\partial h_t} \quad (16)$$

$$\delta_{t-1}^T = \frac{\partial E}{\partial h_{t-1}} \quad (17)$$

$$\delta_k^T = \prod_{j=k}^{t-1} \delta_{o,j}^T w_{oh} + \delta_{f,j}^T w_{fh} + \delta_{i,j}^T w_{ih} \quad (18)$$

Hata terimleri ağ boyunca tersine üst katmana iletilir:

$$\delta = (\delta_{f,t}^T w_{fx} + \delta_{i,t}^T w_{ix} + \delta_{o,t}^T w_{ox} \cdot f'(net_t^{l-1})) \quad (19)$$

Adım 3: Hataya göre ağırlık gradyanını hesaplanır.

$$\frac{\partial E}{\partial w_f} = \sum_{j=1}^t \delta_{fj} \quad (20)$$

w noktadaki en hızlı değere sahip hatadır. Şirketin hata hesaplaması için çoklu endeks kararında, en hızlı değişime sahip endeksi bulur.

Adım 4: Bir önceki adıma göre ağırlıklar güncellenir. Bu makalede kullanılan ek bir derin öğrenme modeli hiyerarşik bir CNN katmanıdır. Hiyerarşik bir CNN, birbirine bağlanabilen ve CNN mimarisi tarafından kapsanabilen çok sayıda CNN katmanından oluşur. Ek olarak, doğrusal olmama özelliği modelin her katmanına dahil edilir ve bu da modelin bir bütün olarak dizinin en kritik yönlerini sıfırlamasına yardımcı olur.

Geçitli doğrusal birimler (GLU) hiyerarşik CNN katmanının çıktısını oluşturmak için kullanılır ve teorik olarak aşağıdaki gibi hesaplanabilir:

$$v([XY]) = X \odot \sigma(Y) \quad (21)$$

Burada $,XY \in \mathbb{R}^d$ GLU'nun girdilerini temsil eder ve $\odot$ eleman bazında üretim fonksiyonunu gösterir σ kullanılır ve bu makale pratikte sigmoid kullanır. CNN katmanları istiflendiğinde, üst katmanlarda bazı bilgiler kaybolabilir. Giriş ve çıkış katmanlarını birbirine bağlamak için bu çalışma artık bağlantılara dayanmaktadır. Denkleme bir artık mekanizma eklendiğinde aşağıdaki sonuçlar elde edilir:

$$h_t^k = v\left(W^l \left[h_{t-\frac{o}{2}}^{k-1}, \dots, h_{t+\frac{o}{2}}^{k-1} \right] + b_w^k\right) + h_t^{k-1} \quad (22)$$

Daha sonra, CNN'in çıktılarını gizli duruma dönüştürmek için tam bağlantılı bir katman benimsenir. h^k , böylece kendi kendine dikkat mekanizması benimsenebilir. Gizli durumdan sonra optimizasyon katmanı, her bir alt göstergenin ağırlığını hesaplayabilen

hiyerarşik CNN katmanının çıktısını daha fazla işlemek için çalışacaktır. Ağırlıkları h^k temelinde hesaplayan denklem şu şekilde gösterilebilir:

$$f_h = \tan h(hW_a h^T + f - b_a) \quad (23)$$

$$A = \text{softmax}(f_h) \quad (24)$$

$$g = Ah = (g_1, g_2, \dots, g_n) \quad (25)$$


Burada f_h her bir risk göstergesinin üretilen derecelendirme puanı, A alt endeksin ağırlığı ve g daha sonra CRF katmanı ve sınıflandırma katmanı tarafından işlenecek olan tüm öz dikkat katmanının çıktısıdır. W_a dikkat parametresi matrisini gösterirken, b_a yanlılık parametresini gösterir. Daha sonra CRF katmanı derlenecektir. Giriş katmanı optimizasyon katmanının çıktısıdır. Bir S dizisi için, giriş matrisi $I = [I_1, I_2, \dots, I_n - 1]^T$ olarak gösterilir, burada $I \in n \times d$ $I_{i,j}$ dizideki i^{th} elemanının j^{th} puanının olasılık puanını gösterebilir. $S = \{x_1^k, x_2^k, \dots, x_n^k\}$ dizisi göz önüne alındığında CRF puanı aşağıdaki gibi hesaplanabilir:

$$f(X, y) = \sum_{i=0}^{s+1} O_{y_i, y_{i+1}} + \sum_{i=1}^s I_{i, y_i} \quad (26)$$


Burada T geçiş matrisini ve $O_{i,j}$ ilgili geçiş skorunu göstermektedir. Nihai risk değerlendirmesini elde etmek için sınıflandırıcı katman kullanılır. Böyle bir süreç matematiksel olarak aşağıdaki gibi gösterilebilir:

$$p_t^i(\theta) = \frac{\exp(y_t^i)}{\sum_{j=1} \exp(y_t^j)} \quad (27)$$


Burada θ tüm parametreleri, T etiket kümesini ve $p_t^i(\theta)$ risk analizinin çıktısını temsil etmektedir.



Şekil 2.14 Yatırım riskleri tahmin modeli



Şekil 2.15 CNN ve LSTM bellek hücresi mimarisi



řekil 2.16 CNN-LSTM modeli akıř diyagramı

3. MATERYAL/METOT

3.1 Materyal

CNN-LSTM'nin etkinliğini göstermek için aynı işletim sistemi ortamında aynı eğitim seti ve test seti verilerini kullanarak MLP, CNN, RNN, LSTM ve CNN-RNN ile karşılaştırmalı bir analiz yapılmıştır. Tüm deneyler Çift Çekirdekli Intel i5, 2.3 GHz 8 GB RAM, 256 GB sabit disk ve macOS Ventura işletim sisteminde gerçekleştirilmiştir. Derin öğrenme algoritmalarının çalıştırılması için Phyton programlama dili ile Anaconda platformunda başlıca TensorFlow, Keras kütüphaneleri kullanılmıştır. Grafik oluşturulmasında Matplotlib ve Seaborn başlıca kullanılan kütüphanelerdir.

3.1.1 Veri seti

Bu deneyde, Federal Reserve Bank of St.Louis'in Araştırma bölümü tarafından Federal Rezerve Ekonomik Veriler (FRED) veri tabanından Oksijen Endüstrisi Üretici Fiyat Endeksi Oksijen Fiyatları deneysel verilerin ana kaynağı olarak kullanılmıştır. Günlük işlem veri seti 1 Haziran 1996'dan 1 Şubat 2025'e kadar 10228 veriden oluşmaktadır. Veriler %80 eğitim kümesi, %20 test kümesi olarak ayrılmıştır. Eğitim kümesi 8182 veriden, test kümesi 2046 veriden oluşmaktadır. Her bir veri, açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı, hacim, iniş ve çıkışlar ve değişim olmak üzere yedi öge içermektedir. Açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı, hacim, ciro, yükseliş ve düşüş ve değişim faktörlerine göre ertesi günün kapanış fiyatı tahmin edilmektedir.

3.1.2 Değerlendirme

CNN-LSTM'nin tahmin performansını değerlendirmek için kullanılan değerlendirme kriterleri arasında kök ortalama kare hata (RMSE), ortalama mutlak yüzde hata (MAPE), doğruluk yüzdesi (MA), ortalama mutlak hata (MAE) ve R-kare (R^2) yer almaktadır. RMSE, MAPE, MA formülleri aşağıda verilmiştir. RMSE ve MAE hesaplamasında y

tahmin değeri y_i ise gerçek değerdir. RMSE değeri ne kadar küçükse, tahmin o kadar iyidir.

$$RMSE = \sqrt{\frac{1}{N} \sum_i^n (\hat{y}_i - y_i)^2} \quad (28)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (29)$$

$$MA = 100 - MAPE \quad (30)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (31)$$

$$R^2 = 1 - \frac{(\sum_{i=1}^n (y_i - \hat{y}_i)^2)/n}{(\sum_{i=1}^n (\bar{y}_i - t\hat{y}_i)^2)/n} \quad (32)$$

Formüllerde n gözlem sayısı, $\hat{y}_i$ tahmin edilen değer iken y_i gerçek değerdir. MAE ve RMSE değerleri 0'a ne kadar yakınsa model o kadar iyi tahminleme yapıyor demektir. Bir başka deyişle, tahmin edilen değer ile gerçek değer arasındaki hata o kadar küçük olur ve tahmin değeri o kadar yüksek olur. R^2 değeri (0,1) arasında değer alır ve 1'e ne kadar yakınsa modelin uyum derecesi o kadar iyi demektir. MA ise adından anlaşıldığı üzere modelin tahmin doğruluk yüzdesidir ve 100'e yaklaştıkça doğruluk derecesi artar.

3.1.3 Uygulama


CNN-LSTM ağının giriş eğitim seti verileri üç boyutlu bir veri vektörüdür. Vektör girdisi (Yok, 10, 8) olmak üzere burada 10 zaman adımının boyutunu ve 8 giriş boyutunu büyüklüğünü gösterir. Veriler ilk olarak tek boyutlu konvolüsyon katmanına girerler. Ardından üç boyutlu bir çıktı vektörü (Yok, 10, 32) elde edilir. Bu çıktı vektörü eğitim için LSTM katmanına girerler ve iki boyutlu (Yok, 64) çıktı verisi elde edilir. Eğitimden

sonra tam bağlantı katmanına geçer. Buradaki 64 sayısı LSTM katmanındaki gizli birimlerin sayısını göstermektedir. Ardından çıktı verisi (Yok, 1) elde edilir.

Geliştirdiğimiz CNN-LSTM modeli giriş katmanı, tek boyutlu konvolüsyon katmanı, tek boyutlu havuzlama katmanı ve tam bağlı katmandan oluşmaktadır. CNN-LSTM dahil karşılaştırdığımız tüm makine öğrenmesi modelleri 100 epok sayısınca eğitilmiştir. 64 toplu iş boyutuna sahip, ortalama mutlak hata fonksiyonu kullanan ADAM optimizasyon algoritması kullanılmıştır. ADAM algoritması parametrelerin gradyan ağırlıklandırmalarını hesaplayarak, öğrenme oranını artırır ve test verilerinin eğitim verilerine yakınsanmasını sağlar. Konvolüsyon ve havuzlama katmanlarında özellik kaybı olmaması için aynı katman dolgusu kullanılmıştır.

Çizelge 3.1 CNN-LSTM modeli parametre değerleri


Parametre	Değer
Konvolüsyon katmanı filtreleri	32
Konvolüsyon katmanı çekirdek boyutu	1
Konvolüsyon katmanı aktivasyon fonksiyonu	tanh
Konvolüsyon katmanı dolgusu	Aynı
Havuzlama katmanı havuz boyutu	1
Havuzlama katmanı dolgusu	Aynı
Havuzlama katmanı aktivasyon fonksiyonu	Relu
LSTM katmanındaki gizli birim sayısı	64
LSTM katmanı aktivasyon fonksiyonu	tanh
Zaman_adımı	10
Toplu iş boyutu	64
Öğrenme oranı	0,001
Optimize edici	ADAM
Kayıp fonksiyonu	ortalama mutlak hata
Epok sayısı	100




Şekil 3.1 CNN-LSTM modelinin yapısı

4. ARAŞTIRMA BULGULARI


İşlenen eğitim seti verilerinin MLP, CNN, RNN, LSTM, CNN-RNN ve CNN-LSTM kullanılarak eğitimle tamamlanan model, hesaplanan riski tahmin etmek için kullanılır. Altı yöntemin karşılaştırmalı sonuçları Şekil 4.1 - Şekil 4.8 ve Çizelge 4.1'de sunulmuştur.




Şekil 4.1 MLP modeli tahmin edilen değer ile gerçek değer karşılaştırması




Şekil 4.2 CNN modeli tahmin değeri ile gerçek değer karşılaştırması




Şekil 4.3 RNN modeli tahmin edilen değer ile gerçek değer karşılaştırması



Şekil 4.4 LSTM modeli tahmin edilen değer ile gerçek değer karşılaştırması




Şekil 4.5 CNN-RNN tahmin edilen değer ile gerçek değer karşılaştırması




Şekil 4.6 CNN-LSTM tahmin edilen değer ile gerçek değer karşılaştırması

Çizelge 4.1 Farklı makine öğrenmesi modellerinin tahmin karşılaştırması


Yöntem	RMSE	MAE	MAPE(%)	MA(%)	R^2
MLP	0.304	0.238	5.82	94.18	0.9487
CNN	0.208	0.160	4.6	95.4	0.9583
RNN	0.184	0.142	3.8	96.2	0.9623
LSTM	0.147	0.136	3.1	96.9	0.9698
CNN-RNN	0.142	0.129	3.0	97.0	0.9738
CNN-LSTM	0.138	0.124	2.8	97.2	0.9847




Şekil 4.7 Farklı makine öğrenmesi yöntemlerinin RMSE karşılaştırması




Şekil 4.8 Farklı makine öğrenmesi yöntemlerinin MAE karşılaştırması




Şekil 4.9 Farklı makine öğrenmesi yöntemlerinin MAPE karşılaştırması



Şekil 4.10 Farklı makine öğrenmesi yöntemlerinin MA karşılaştırması



Şekil 4.11 Farklı makine öğrenmesi yöntemlerinin R² karşılaştırması



Şekil 4.12 Makine öğrenmesi yöntemlerinin gürültü altında çalışma sonuçları

5. TARTIŞMA

Oluşturduğumuz CNN-LSTM modeli ile MLP, CNN, RNN, LSTM, CNN-RNN modellerinin tahmin değerleri ve performans metrikleri karşılaştırılmıştır. Çizgi grafiğinde görüldüğü üzere gerçek değer ile tahmin edilen değer arasındaki en yakınsak eğim uyumu CNN-LSTM modeline aittir ve sırasıyla CNN-RNN, LSTM, CNN, RNN ve MLP olmak üzere modelin fiyat tahmin becerisi azalmakta, gerçek değerler ile tahmin edilen değerler arasındaki boşluk artmaktadır.

CNN-LSTM modeli ve MLP, CNN, RNN, LSTM, CNN-RNN modellerinin regresyon performans ölçümünü yapmak için sırasıyla Hataların Karesinin Ortalama Karekökü (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Hata Yüzdesi (MAPE), Ortalama Doğruluk (MA) ve Belirtme Katsayısı (R^2) ölçütleri kullanılmış ve modellerin tahmin değerlendirme performansları karşılaştırılmıştır.

Test edilen tüm modellerin performans metrikleri oldukça iyidir ve gerçeğe çok yakın sonuç vermektedir. Bu durum veri sayısının büyüklüğünden ve zaman serisi yapısındaki verilerimizi en iyi tahminleyen makine öğrenmesi modellerini seçmemizden kaynaklanmaktadır. Önerdiğimiz CNN-LSTM modeli sırasıyla RMSE ölçütü için 0.138, MAE ölçütü için 0.124, MAPE ölçütü için %2.8 hata değerlerini alarak 0'a yaklaştırmış, hata ölçüm endekslerinde en hatasız sonucu vermiştir. MA değeri %97.2 olup %100 doğruluk seviyesine en yakın sonucu vermiştir. R^2 belirtme katsayısında 0.9847 değerini alarak 1'en yakın sonuç vererek uygulanan modeller arasında veriyi en iyi açıklayan ve tahminleyen model olduğunu ortaya koymuştur.

CNN-LSTM modeli CNN-RNN ile karşılaştırıldığında hata ölçüm değerleri RMSE 0.138'den 0.142'ye, MAE 0.124'ten 0.129'a, MAPE 2.8'den 3.0'e yükselmiştir. Modellerin ortalama doğruluğu MA 97.2'den 97.0'e, uyum iyiliği R^2 0.9847'den 0.9738'e düşmüştür. LSTM modeli ile RNN modelini karşılaştırdığımızda RMSE değerinin 0.147'den 0.184'e, MAE değerinin 0.136'dan 0.142'ye, MAPE değerinin 3.1'den 3.8'e yükselerek hata değerlerinin arttığını görürken; MA yüzde değerinin 96.9'dan 96.2'ye, R^2 belirtme değerinin 0.9623'ten 0.9538'e gerilediğini görmekteyiz. O

halde, hem CNN katmanının eklendiği hem de eklenmediği durumda, LSTM modelinin bellek fonksiyonu ile bilgiyi uzun sürede hafızada tutabilmesi ve geçit mekanizmaları sayesinde kaybolan gradyan problemini çözmesiyle RNN modelinden daha iyi performans sergileyerek hata metriklerinde düşüş sağlamıştır. Kullandığımız veri setinin zaman serisi olması da LSTM'nin uzun vadeli trendleri ve dalgalanmaları hafızasında tutabilmesi sebebiyle modelleme başarısını arttırmıştır.

Bununla birlikte CNN katmanının LSTM ve RNN katmanlarına eklenmesiyle oluşan CNN-LSTM ve CNN-RNN modellerinde hata oranının daha da azaldığını, uyum iyiliği yükseldiğini görebiliriz. Şöyle ki; CNN-LSTM modeli LSTM modeli ile sırasıyla mukayese edildiğinde RMSE değeri 0.138'den 0.147'e, MAE değeri 0.124'ten 0.160'a, MAPE değeri 2.8'den 3.1'e yükselerek hata endeksleri yükselmiştir. LSTM modelinden CNN-LSTM modeline geçiş yapıldığında MA doğruluk yüzdesi 96.9'dan 97.2'ye artmış, R^2 uyumluluk derecesi 0.9698'den 0.9847'e yükselmiştir. Aynı şekilde CNN-RNN modeli ile RNN modelini karşılaştırdığımızda sırasıyla RMSE değeri 0.142'den 0.184'e, MAE değeri 0.129'dan 0.142'ye, MAPE yüzdesi 3.0'ten 5.82'ye çıkmış; bir diğer deyişle modelin hata oranı artmıştır. RNN modelinden CNN-RNN modeline geçiş yaptığımızda MA yüzdesi 96.2'den 97.0'e artarak modelin doğruluk yüzdesi 0.8 puan artmış; R^2 uyum iyiliği 0.9623'ten 0.9738'e yükselerek ideal R^2 sayısı 1'e 0.0115 puan daha da yaklaşmıştır. CNN modelinde konvolüsyon katmanının giriş verisindeki en belirgin veri özelliklerini seçmesi, havuzlama katmanının ise özellik haritalarının boyutunu azaltarak özellik haritasındaki bilgiyi yoğunlaştırması sayesinde; CNN katmanının LSTM ve RNN modellerine eklendiğinde tahmin performansını iyileştirdiğini belirtebiliriz. CNN'in verideki önemli özellikleri filtreleyerek, LSTM ve RNN'in daha istikrarlı ve güvenilir tahminler yapmasına yardımcı olması, özellikle yatırım projelerinin risk analizinde fiyat gibi kritik faktörlerin doğru tahminlenmesi ve bilinçli kararlar alınması açısından önemlidir.

MLP çok katmanlı algılayıcı modeli RMSE, MAE, MAPE hata ölçütleri için sırasıyla 0.304, 0.238 ve 5.82 değerlerini alarak diğer modellere göre en yüksek hata oranını vermiştir. MA doğruluk yüzdesi için 94.18, R^2 model uyum katsayısı için 0.9487 değerlerini alarak en düşük tahminleme performansını göstermiştir. Bu durum MLP'nin

zamansal bağımlılıkları doğrudan modelleyememesinden kaynaklanmaktadır. Uyguladığımız diğer makine öğrenmesi modellerine kıyasla daha az katman sayısına ve daha basit bir yapıya sahip olduğu için verideki karmaşık ilişkileri yakalama yeteneği sınırlıdır. MLP'den CNN modeline geçildiğinde RMSE değeri 0.196, MAE değeri 0.78 , MAPE değeri %1.12 gerileyerek modelin hata oranı azalmıştır. Modelin veriyi açıklama yüzdesi MA %95.4, R^2 değeri 0.9583 olmuş model performans metriklerinde iyileşme göstermiştir. RNN ile CNN modelini karşılaştırdığımızda ise RNN modelinin RMSE, MAE, MAPE, MA ve R^2 değerleriyle sırasıyla 0.184, 0.142, %3.8, %96.2 ve 0.9623 değerlerini almıştır. RNN modelinin yinelemeli yapısını sayesinde zaman serisindeki zamansal bağımlılıkları modelleme yeteneğine sahip olması hata metriklerinde düşüş oluşturup, performans iyileştirmesi sağlamıştır.

Yapılan karşılaştırmalı analiz, önerdiğimiz CNN-LSTM modelinin yatırım projelerinin risk analizinde fiyat gibi kritik faktörlerin tahminlenmesi için uygun model olduğunu göstermektedir. CNN ve LSTM modellerinin birleşiminden oluşan bu hibrit yaklaşım, hem verideki yerel kalıpları hem de zaman içindeki uzun vadeli bağımlılıkları modelleyebilmesi sayesinde, diğer modellere göre daha doğru ve güvenilir tahminler yapabilmektedir.

Ancak, modelin bazı eksiklikleri de bulunmaktadır. Örneğin, sadece fiyat verilerinin kapanış fiyatları üzerindeki etkisini dikkate almakta ve ulusal politika, enflasyon gibi kalitatif faktörleri tahmine entegre edememektedir.

6. SONUÇ

Yatırım projelerinin riskinin belirlenmesinde kullanılan geleneksel yöntemler, projenin karlılığını en çok etkileyen değişkenleri bulmakta, bu değişkenlerin değişme aralıklarını ve ilgili aralıklar içinde bir değerin ortaya çıkma olasılığını belirlemeye çalışmaktadırlar. Kritik değişkene ilişkin gerçeğe en yakın bilgiye ulaşmak adına ayrıntılı geçmiş dönem değerlerini ve eğilimlerini incelenmekte; sınırlı bilginin sözkonusu olduğu durumlarda sübjektif bilgi ve deneyime dayanarak belirlenen risk faktörünün olası değeri ve değişkenin durumuna en iyi uyduğu düşünülen istatistik dağılıma benzetilmeye çalışılmaktadır.

Oksijen üretimi gibi yüksek sermaye gerektiren projelerde fiyat parametresi projenin ekonomik sürdürülebilirliğini, getirisini ve karlılığını belirleyen kritik bir risk faktörüdür. Risk ölçümünde sıklıkla yararlanılan net bugünkü değer (NPV) ve iç getiri oranı (IRR) ile gerçekleştirilen duyarlılık analizinde de ürün fiyatı projenin gelirini belirleyen en mühim faktör olarak karşımıza çıkmaktadır. Gelecekteki fiyat hareketleri, işletmenin maruz kalacağı kayıpları, sermaye ihtiyacını ve alınacak önlemleri doğrudan belirlemektedir. Yanlış fiyat tahmini yatırım kararı sonuçlarını bozabilmekte; fiyatlardaki beklenmeyen değişim gelir akışlarını etkileyerek işletme sermayesini ve likidite ihtiyacını değiştirebilmektedir. Fiyatların öngörülemeyen düşüşü yatırımın kar marjını düşürmekte ve yatırımın geri dönüş süresini uzatmaktadır. Oluşan nakit akış güvensizliği işletmenin kredi maliyetini arttırmakta, finansman edinme koşullarını zorlaştırmaktadır. İşletme öngöremediği bir fiyat değişikliğinde rekabet edemez, ölçeklenip genişleyemez hale gelebilmektedir; bu durum yatırımın durdurulmasına ve tüm sermayenin israf olmasına sebep olabilmektedir.

Fiyatın hassas ve yatırım kararı üzerinde etkili bir değişken olması nedeniyle analistin şahsi görüşüne dayalı senaryo analizleri ve olasılık dağılımını içeren Monte-Carlo simülasyonları yapılmaktadır. Literatür ve değerlendirme raporları incelendiğinde makine öğrenmesi sayesinde veri manipülasyonuna ve sübjektif etkilere maruz kalınmadan fiyat tahminlemesinin yapılabileceği görülmüştür. Bu amaçla tezimizde

nesnel ve akılcı bir yöntem olarak makine öğrenmesi yöntemleri ile risk analizinde karlılığı en çok etkileyen risk faktörü olan fiyat parametresinin tahmini yapılmıştır.

Makine öğrenmesi yöntemi olarak zaman serilerinde en etkili özellikleri çıkararak belirgin unsurlara odaklanılmasını sağlayan CNN ile hafıza fonksiyonu sayesinde veriler arasında ilişki kurabilen LSTM modelinin birleştirilmesiyle giriş katmanı, tek boyutlu konvolüsyon katmanı, havuzlama katmanı, LSTM gizli katmanı ve tam bağlı katmandan oluşan yeni bir CNN-LSTM makine öğrenmesi modeli geliştirilmiştir. Modelimizde Federal Reserve Ekonomik Veriler veritabanının Oksijen Endüstrisi Üretici Fiyat Endeks verileri kullanılmıştır. Girdi olarak açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı, hacim, ciro, artış ve düşüşler ile değişim yüzdesi kullanılarak, bir sonraki günün oksijen fiyatı tahmin edilmiştir.

Ardından modelimizin performansı MLP, CNN, RNN, LSTM, CNN-RNN modelleriyle karşılaştırılmıştır. Performans karşılaştırma ölçütleri olarak RMSE, MAE, MAPE, MA ve R^2 ölçütleri kullanılmıştır. Oluşturduğumuz evrişimli ağlar ve uzun kısa süreli bellek modelini birleştiren CNN-LSTM modeli hata ölçüt endekslerinden aldığı RMSE = 0.138, MAE = 0.124, MAPE = %2.8 değerleriyle, doğruluk oranı MA = %97.2 ve R^2 = 0.9847 uyum derecesi değerleriyle diğer altı modele kıyasla en iyi performansı göstermiştir. Hibrit bir yaklaşım olan CNN-LSTM, hem verideki yerel kalıpları hem de zaman içindeki uzun vadeli bağımlılıkları modelleyebilmesi nedeniyle diğer modellere göre daha doğru ve güven Çalışma, yatırım projelerinin risk analizinde makine öğrenimi tekniklerinin kullanılmasının, fiyat gibi en kritik risk faktörlerini tahminlemek adına oldukça faydalı olduğunu ortaya koymaktadır.

KAYNAKLAR

- Ala'raj, Maher, and Maysam F. Abbod. 2016a. A New Hybrid Ensemble Credit Scoring Model Based on Classifiers Consensus System Approach. *Expert Systems with Applications* 64: 36–55.
- Ala'Raj, Maher, and Maysam F. Abbod. 2016b. Classifiers Consensus System Approach for Credit Scoring. *Knowledge-Based Systems* 104: 89–105.
- Apostolik, Richard, Christopher Donohue, Peter Went, and Global Association of Risk Professionals. 2009. *Foundations of Banking Risk: An Overview of Banking, Banking Risks, and Risk-Based Banking Regulation*. New York: John Wiley.
- Arezzo, Maria, and Giuseppina Guagnano. 2018. Response-Based Sampling for Binary Choice Models with Sample Selection. *Econometrics* 6: 12.
- Awad, Mariette, and Rahul Khanna. 2015. *Machine Learning in Action: Examples. Efficient Learning Machines*.
- Aziz, Saqib, and Michael M. Dowling. 2018. AI and Machine Learning for Risk analysis. *SSRN Electronic Journal*.
- Barboza, Flavio, Herbert Kimura, and Edward Altman. 2017. Machine learning models and bankruptcy prediction. *Expert Systems with Applications* 83: 405–17.
- Basel Committee on Banking Supervision. 2005a. Guidance on Paragraph 468 of the Framework Document. Basel: Bank for International Settlements.
- Basel Committee on Banking Supervision. 2005b. An Explanatory Note on the Basel II IRB Risk Weight Functions. Basel: Bank for International Settlements.
- Basel Committee on Banking Supervision. 2006. Minimum Capital Requirements for Market Risk. Basel: Bank for International Settlements.
- Basel Committee on Banking Supervision. 2008. Principles for Sound Liquidity Risk analysis and Supervision. Basel: Bank for International Settlements.
- Basel Committee on Banking Supervision. 2011. Principles for the Sound Management of Operational Risk. Basel: Bank for International Settlements, pp. 1–27.
- Bastos, João A. 2014. Ensemble Predictions of Recovery Rates. *Journal of Financial Services Research* 46: 177–93.
- Bauguess, Scott W. 2015. *The Hope and Limitations of Machine Learning in Market Risk Assessment*. Washington, DC: U.S. Securities and Exchange Commission.
- Bellotti, Tony, and Jonathan Crook. 2009. Support Vector Machines for Credit Scoring and Discovery of Significant Features. *Expert Systems with Applications*.

- Blom, Tineke. 2015. Top down Stress Testing: An Application of Adaptive Lasso to Forecasting Credit Loss Rates. Master's Thesis, Faculty of Science, Hongkong, China.
- Brown, Iain, and Christophe Mues. 2012. An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications* 39: 3446–53.
- Cao, Jie, Hongke Lu, Weiwei Wang, and Jian Wang. 2013. A Loan Default Discrimination Model Using Cost-Sensitive Support Vector Machine Improved by PSO. *Information Technology and Management* 14: 193–204.
- Chan-Lau, Jorge. 2017. Lasso Regressions and Forecasting Models in Applied Stress Testing. *IMF Working Papers* 17: 1.
- Chen, Ning, Bernardete Ribeiro, and An Chen. 2016. Financial Credit Risk Assessment: A Recent Review. *Artificial Intelligence Review* 45: 1–23.
- Dal Pozzolo, Andrea. 2015. Adaptive Machine Learning for Credit Card Fraud Detection. Unpublished doctoral dissertation, Université libre de Bruxelles, Faculté des Sciences—Informatique, Bruxelles.
- Deloitte University Press. 2017. Global Risk analysis Survey, 10th ed. Deloitte University Press: <https://www2.deloitte.com/tr/en/pages/risk/articles/global-risk-management-survey-10th-ed.html> (Erişim Tarihi: 1 Haziran 2022).
- Domingos, P. "A few useful things to know about machine learning," *Communications of the ACM*, vol. 55, no. 10, pp. 7887, 2012.
- Financial Stability Board. 2017. Artificial Intelligence and Machine Learning in Financial Services. Market Developments and Financial Stability Implications. Financial Stability Board. November 1. Available online: <http://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/> (Erişim Tarihi: 9 Mayıs 2022).
- Galindo, Jorge, and Pablo Tamayo. 2000. Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications. *Computational Economics* 15: 107–43.
- Gotoh, Jun-ya, Akiko Takeda, and Rei Yamamoto. 2014. Interaction between financial risk measures and machine learning methods. *Computational Management Science* 11: 365–402.
- Greene, William H. 1992. A Statistical Model for Credit Scoring. NYU Working Paper No. EC-92-29. Available online: <https://ssrn.com/abstract=1867088> (Erişim Tarihi: 8 Mayıs 2022).

- Guegan, Dominique, Peter Addo, and Bertrand Hassani. 2018. Credit risk analysis using machine and deep learning models. *Risks* 6: 38.
- Hamori, Shigeyuki, Minami Kawai, Takahiro Kume, Yuji Murakami, and Chikara Watanabe. 2018. Ensemble Learning or Deep Learning? Application to Default Risk Analysis. *Journal of Risk and Financial Management* 11: 12.
- Hand, David J., and William E. Henley. 1997. Statistical Classification Methods in Consumer Credit Scoring: A Review. *Journal of the Royal Statistical Society Series A: Statistics in Society*.
- Harris, Terry. 2013. Quantitative credit risk assessment using support vector machines: Broad versus Narrow default definitions. *Expert Systems with Applications* 40: 4404–13.
- Helbekkmo, Hans, Alok Kshirsagar, Andreas Schlosser, Francesco Selandari, Uwe Stegemann, and Joyce Vorholt. 2013. Enterprise Risk analysis—Shaping the Risk Revolution. New York: McKinsey & Co., Available online: www.rmahq.org (accessed on 18 June 2018).
- Hochreiter, S. ve Schmidhuber, J. 1997. Long short-term memory, MIT Press, cilt 9, no. 8, s. 1735-1780.
- Huang, Cheng Lung, Mu Chen Chen, and Chieh Jen Wang. 2007. Credit Scoring with a Data Mining Approach Based on Support Vector Machines. *Expert Systems with Applications* 33: 847–56.
- Hull, John. 2012. Risk analysis and Financial Institutions. New York: John Wiley and Sons, vol. 733.
- Islam, Tushith, Christos Vasilopoulos, and Erik Pruyt. 2013. Stress—Testing Investment projects under Deep Uncertainty.
- Jacobs, Michael, Jr. 2018. The validation of machine-learning models for the stress testing of credit risk. *Journal of Risk analysis in Financial Institutions* 11: 218–43.
- Jorion, Philippe. 2007. Value at Risk: The New Benchmark for Managing Financial Risk. New York: McGraw-Hill.
- Kanevski, Mikhail F., and Vadim Timonin. 2010. Machine learning analysis and modeling of interest rate curves. Paper presented at the 18th European Symposium on Artificial Neural Networks ESANN, Bruges, Belgium, April 28–30; Available online: <https://www.elen.ucl.ac.be/Proceedings/esann/esannpdf/es2010-17.pdf>
- Kannan, Somasundaram, and K. Somasundaram. 2017. Autoregressive-Based Outlier Algorithm to Detect Money Laundering Activities. *Journal of Money Laundering Control* 20: 190–202.
- Keramati, Abbas, and Niloofar Yousefi. 2011. A proposed classification of data mining techniques in credit scoring. Paper presented at the 2011 International Conference

of Industrial Engineering and Operations Management, Kuala Lumpur, Malaysia, January 22–24.

- Khandani, Amir E., Adlar J. Kim, and Andrew W. Lo. 2010. Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance* 34: 2767–87.
- Khrestina, Marina Pavlovna, Dmitry Ivanovich Dorofeev, Polina Andreevna Kachurina, Timur Rinatovich Usubaliev, and Aleksey Sergeevich Dobrotvorskiy. 2017. Development of Algorithms for Searching, Analyzing and Detecting Fraudulent Activities in the Financial Sphere. *European Research Studies Journal* 20: 484–98.
- Lai, Kin Keung, Lean Yu, Ligang Zhou, and Shouyang Wang. 2006. Credit risk evaluation with least square support vector machine. In *International Conference on Rough Sets and Knowledge Technology*. Berlin/Heidelberg: Springer, pp. 490–95.
- Lecun, Y., Bottou, L., Bengio, Y., ve P. Haffner. 1998. "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324
- Lessmann, Stefan, Bart Baesens, Hsin Vonn Seow, and Lyn C. Thomas. 2015. Benchmarking State-of-the-Art Classification Algorithms for Credit Scoring: An Update of Research. *European Journal of Operational Research* 247: 124–36.
- Liu, Y. 2019. Novel Volatility Forecasting Using Deep Learning-Long Short Term Memory Recurrent Neural Networks Expert Systems with Application, Vol.132, 2019, pp.99-109.
- Mahdavi-Damghani, Babak, and Stephen Roberts. 2017. A Proposed Risk Modeling Shift from the Approach of Stochastic Differential Equation towards Machine Learning Clustering: Illustration with the Concepts of Anticipative and Responsible VaR. *SSRN Electronic Journal*.
- Mainelli, Michael, and Mark Yeandle. 2006. Best execution compliance: New techniques for managing compliance risk. *The Journal of Risk Finance* 7: 301–12.
- Malhotra, Rashmi, and D. K. Malhotra. 2003. Evaluating Consumer Loans Using Neural Networks. *Omega* 31: 83–96.
- Monfared, Soheil Almasi, and David Enke. 2014. Volatility Forecasting Using a Hybrid GJR-GARCH Neural Network Model. *Procedia Computer Science* 36: 246–53.
- Ngai, Eric W. T., Yong Hu, Yiu Hing Wong, Yijun Chen, and Xin Sun. 2011. The Application of Data Mining Techniques in Financial Fraud Detection: A Classification Framework and an Academic Review of Literature. *Decision Support Systems* 50: 569.

- Özcan, D., Askerzade, İ. ve Bostancı, G. E. 2022. Risk Analysis of an Investment Project Using Deep Learning Techniques, Proceeding of the International Conference on Control and Optimization with Industrial Applications, pp. 319-329.
- Özcan Yaylalı, D., Askerzade, İ. 2025. The Application of Machine Learning Methods for Risk Analysis of Investment Projects, Proceeding of International Conference on Problems of Cybernetics and Informatics, Vol.2025, pp.294.
- Raei, Reza, Mahdi Saeidi Kousha, Saeid Fallahpour, and Mohammad Fadaeinejad. 2016. A Hybrid Model for Estimating the Probability of Default of Corporate Customers. *Iranian Journal of Management Studies* 9: 651–73.
- Sala, Jordi Petchamé. 2011. Liquidity Risk Modeling Using Artificial Neural Network. Master's thesis, Universitat Politècnica de Catalunya, Barcelona, Spain.
- Sariaslan, H. 2019. Planning and Analyzing Foreign Direct Investment Projects: Emerging Research and Opportunities. Hershey: IGI Global Scientific Publishing.
- Saunders, Anthony, Marcia Millon Cornett, and Patricia Anne McGraw. 2006. *Financial Institutions Management: A Risk analysis Approach*. New York: McGraw-Hill.
- Shalev-Shwartz, Shai, and Shai Ben-David. 2014. *Understanding Machine Learning: From Theory to Algorithms*. Cambridge: Cambridge University Press.
- Sharma, Shashank, and Arjun Roy Choudhury. 2016. Fraud Analytics: A Survey on Bank Fraud Prediction Using Unsupervised Learning Based Approach. *International Journal of Innovation in Engineering Research and Technology* 3: 1–9.
- Sohangir, S., Wang, D., Pomeranets, A. 2018. Big Data: Deep Learning for financial sentiment analysis", *Journal of Big Data*, Vol.5, No.1, pp.3.
- Song, J.T. 2021. Construction of Corporate Investment Decision Support Model Based on Deep Learning", *Scientific Programming*, Vol.2021, pp.1-7.
- Sudjianto, Agus, Sheela Nair, Ming Yuan, Aijun Zhang, Daniel Kern, and Fernando Cela-Díaz. 2010. Statistical Methods for Fighting Financial Crimes. *Technometrics* 52: 5–19.
- Tavana, Madjid, Amir Reza Abtahi, Debora Di Caprio, and Maryam Poortarigh. 2018. An Artificial Neural Network and Bayesian Network Model for Liquidity Risk Assessment in Banking. *Neurocomputing* 275: 2525–54.
- Xie, M., Li, H. ve Zhao, Y. 2020. Blockchain financial investment based on deep learning network algorithm", *Journal of Computational and Applied Mathematics*, pp.372.
- Vaidya, Avanti H., and Sudhir W. Mohod. 2014. Internet Banking Fraud Detection using HMM and BLAST-SSAHA Hybridization. *International Journal of Science and Research (IJSR)* 3: 574–9.

- Van Gestel, Ir Tony, Bart Baesens, Ir Joao Garcia, and Peter Van Dijcke. 2003. A support vector machine approach to credit scoring. In *Forum Financier—Revue Bancaire Et Financière Bank En Financiewezen*. Bruxelles: Larcier, pp. 73–82. Available online: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.93.6492&rep=rep1&type=pdf> (accessed on 7 July 2018).
- Van Liebergen, Bart. 2017. Machine Learning: A Revolution in Risk analysis and Compliance? *Journal of Financial Transformation* 45: 60–67.
- Van-Sang, Ha, and Ha-Nam Nguyen. 2016. Credit Scoring with a Feature Selection Approach Based Deep Learning. In *MATEC Web of Conferences*. Les Ulis: EDP Sciences, volume 54, p. 05004. Available online: https://www.matec-conferences.org/articles/mateconf/abs/2016/17/mateconf_mimt2016_05004/mateconf_mimt2016_05004.html (accessed on 19 July 2018).
- Villalobos, Miguel Agustín, and Eliud Silva. 2017. A Statistical and Machine Learning Model to Detect Money Laundering: An Application. Available online: http://hddavii.eventos.cimat.mx/sites/hddavii/files/Miguel_Villalobos.pdf (accessed on 21 June 2018).
- Wang, Yongqiao, Shouyang Wang, and Kin Keung Lai. 2005. A New Fuzzy Support Vector Machine to Evaluate Credit Risk. *IEEE Transactions on Fuzzy Systems* 13: 820–31.
- Wang, Hong, Qingsong Xu, and Lifeng Zhou. 2015. Large Unbalanced Credit Scoring Using Lasso-Logistic Regression Ensemble. *PLoS ONE* 10: e0117844.
- Wójcicka, Aleksandra. 2017. Neural Networks vs. Discriminant Analysis in the Assessment of Default. *Electronic Economy*, 339–49.
- Yang, Zijiang, Wenjie You, and Guoli Ji. 2011. Using partial least squares and support vector machines for bankruptcy prediction. *Expert Systems with Applications* 38: 8336–42.
- Yao, Xiao, Jonathan Crook, and Galina Andreeva. 2015. Support vector regression for loss given default modelling. *European Journal of Operational Research* 240: 528–38.
- Yao, Xiao, Jonathan Crook, and Galina Andreeva. 2017. Enhancing two-stage modelling methodology for loss given default with support vector machines. *European Journal of Operational Research* 263: 679–89.
- Yeh, I. Cheng, and Chehui Lien. 2009. The Comparisons of Data Mining Techniques for the Predictive Accuracy of Probability of Default of Credit Card Clients. *Expert Systems with Applications*.
- Yu, Lean, Zebin Yang, and Ling Tang. 2016. A Novel Multistage Deep Belief Network Based Extreme Learning Machine Ensemble Learning Paradigm for Credit Risk Assessment. *Flexible Services and Manufacturing Journal* 28: 576–92.

- Zareapoor, Masoumeh, and Pourya Shamsolmoali. 2015. Application of Credit Card Fraud Detection: Based on Bagging Ensemble Classifier. *Procedia Computer Science* 48: 679–86.
- Zhang, Wenhao. 2017. Machine Learning Approaches to Predicting Company Bankruptcy. *Journal of Financial Risk analysis* 6: 364–74.
- Zhang, Heng Guo, Chi Wei Su, Yan Song, Shuqi Qiu, Ran Xiao, and Fei Su. 2017. Calculating Value-at-Risk for High-Dimensional Time Series Using a Nonlinear Random Mapping Model. *Economic Modelling* 67: 355–67.
- Zhou, Lifeng, and Hong Wang. 2012. Loan Default Prediction on Large Imbalanced Data Using Random Forests. *TELKOMNIKA Indonesian Journal of Electrical Engineering*.