

# **MAKİNE ÖĞRENMESİNİN MUHASEBE VE FİNANSMAN ALANINDA KULLANIMI**

**Sena YILDIZ**

(Galatasaray Üniversitesi, Kurumsal Yönetim, Denetim ve Uyum Çalışmaları  
Uygulama ve Araştırma Merkezi (GSUKUYDEM))

**Prof. Dr. Volkan DEMİR**

(Galatasaray Üniversitesi, İİBF, İşletme Bölümü ve  
Kurumsal Yönetim, Denetim ve Uyum Çalışmaları Uygulama ve Araştırma Merkezi  
(GSUKUYDEM))



**Eylül, 2021**





**İSTANBUL SERBEST MUHASEBECİ MALİ MÜŞAVİRLER ODASI**  
**ISTANBUL CHAMBER OF CERTIFIED PUBLIC ACCOUNTANTS**

# **MAKİNE ÖĞRENMESİNİN**

---

# **MUHASEBE VE FİNANSMAN**

---

# **ALANINDA KULLANIMI**

**Sena YILDIZ**

(Galatasaray Üniversitesi, Kurumsal Yönetim, Denetim ve Uyum Çalışmaları  
Uygulama ve Araştırma Merkezi (GSUKUYDEM))

**Prof. Dr. Volkan DEMİR**

(Galatasaray Üniversitesi, İİBF, İşletme Bölümü ve  
Kurumsal Yönetim, Denetim ve Uyum Çalışmaları Uygulama ve Araştırma Merkezi  
(GSUKUYDEM))

Eylül, 2021

E-ISBN: 978-975-555-261-3

## SUNUŞ

Değerli Meslektaşlarımız ve Stajyerlerimiz,

Mesleki Uzmanlaşma Komite'mizin faaliyet dönemi içinde çalışma alanlarından biri olan "Makine Öğrenmesinin Muhasebe ve Finansman Alanında Kullanımı" isimli çalışmayı hazırlayan Prof. Dr. Volkan Demir'e ve Sena Yıldız'a kıymetli çalışmaları için teşekkür eder, çalışmalarınızda kolaylıklar dilerim.

**Saygılarımla,**

**Yücel Akdemir**

*İSMMMO Başkanı*

Adnan Berber	MESLEKİ UZMANLAŞMA KOMİTESİ Başkanı
Atilla Artan	MESLEKİ UZMANLAŞMA KOMİTESİ Başkan Yrd
Aysel Sancak	MESLEKİ UZMANLAŞMA KOMİTESİ Sekreteri
Feride Bilgiç Kugu	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Fuat Sayar	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Nail Çakmak	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Mustafa Demirtaş	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Melek Tikveşli	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Nazmiye Akarslan Durgut	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Nejla Othan	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Can Şaygil	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi
Özlem Yıldız	MESLEKİ UZMANLAŞMA KOMİTESİ Üyesi



## İÇİNDEKİLER

GİRİŞ	7
1. MAKİNE ÖĞRENMESİ	9
1.1. Endüstri 4.0 ve Makine Öğrenmesi	9
1.1.1 Veri Madenciliği	12
1.2. Makine Öğrenmesi Teknikleri	13
1.2.1. Destek Vektör Makinesi (Support Vector Machine)	15
1.2.2. Doğrusal Regresyon (Linear Regression)	15
1.2.3. Sinir Ağları (Neural Network)	16
1.2.4. Naive Bayes Algoritması	16
1.2.5. Lojistik Regresyon (Logistics Regression)	16
1.2.6. Karar Ağacı (Decision Tree)	16
1.2.7. K - Ortalamalar Algoritması (K - Means)	17
2. MAKİNE ÖĞRENMESİNİN MUHASEBE VE FİNANS ALANINDAKİ UYGULAMALARI VE ETKİSİ	17
2.1. Finansal Bir Araç Olarak Makine Öğrenmesi	17
2.1.1. Muhasebe ve Finansman Alanındaki Zorluklara Yönelik Makine Öğrenmesi	22
2.1.2. Muhasebe ve Finansman Alanında Makine Öğrenmesi ve Açıklanabilirliği	24
2.2. Muhasebe ve Finansman Uygulamaları ve Makine Öğrenmesi	25
2.2.1. Kredi Risk Analizi ve Tahmin Uygulamaları	26
2.2.2. Hızlı Türev Fiyatlandırma	28
2.2.3. Kurumsal Performansın Değerlendirilmesi ve Yatırım Kararları	29
2.2.4. Hisse Senedi ve Borsa Verilerinin Öngörüsü	31
2.2.5. Kişisel Finansal İşlem Endeksi Puanlaması	32
2.2.6. Tedarik Zinciri Finansmanında KOBİ'lerin Kredi Risk Tahmini	34
2.2.7. Risk Sermayesi Kararı	36
2.2.8. Kripto Para Birimi Endeksinin Tahmin Edilmesi	38
2.2.9. Finansal Dolandırıcılık ve Firmalardaki Usulsüzlüklerin Tespiti	40
2.2.10 Finansal Krizin Erken Tahmini	43
2.2.11 Muhasebede Denetim Aracı Olarak Makine Öğrenmesi	44
SONUÇ	48
KAYNAKÇA	49
ŞEKİL LİSTESİ	
Şekil 1: Yapay Zeka ve Makine Öğrenmesinin Benimsenmesinin Arz ve Talep Faktörleri	25
Şekil 2: Makine öğrenmesine dayalı girişim sermayesi diyagramı	37
Şekil 3: ARIMA modeli kullanılarak kripto para endeksi tahmin süreci	39

## GİRİŞ

Makine öğrenmesi, büyük miktarda veriden öğrenerek günümüzde verilerin hatasız ve görece daha hızlı işlenmesine olanak tanıyan, gelecekteki olaylar hakkında öngörüler sağlayan ve yaşanması muhtemel senaryolara dair doğru kararlar alınabilmesini destekleyen teknolojik bir gelişme olarak karşımıza çıkmaktadır ve zaman içerisinde kullanım alanlarını da geliştirerek çok sayıda farklı alanda kullanılmaktadır.

Şirketler elde etmiş oldukları çok sayıda verinin giderek artan karmaşıklığı karşısında kaçınılmaz olarak makine öğrenmesi araçlarına yönelmiştir. Teknolojinin de gelişmesi ile birlikte, makine öğrenmesi araçları ile destek sağlanmadan finansman ve muhasebe alanlarındaki uygulamaların yürütülmesi güçleşmektedir. Makine öğrenmesi, özellikle finans şirketlerine, muhasebecilere ve denetçilere birçok görevi yerine getirerek avantaj sağlama noktasında etkilidir.

Bankalar için kredi yönetiminde ortaya çıkması muhtemel olan risklerin ölçülebilmesi, riskten korunmak ve uyumlaştırmak için türev fiyatlarının alış - satış fiyat değişikliğinin tahmin edilerek hızlı tepkiler verilmesinin sağlanabilmesi, kurumsal performansın değerlendirilmesi ve yatırım kararları verilmesinin kolaylaştırılması, hisse senedi fiyatlarının öngörülebilmesi ve yatırımcılar için alım - satım stratejilerinin oluşturulmasına destek sağlanması, KOBİ'lerin artan kredi kullanım oranları ile artan kredi risk oranının daha doğru bir şekilde tahmin edilmesi, işletmelerin satış ve kar planlaması ile yatırım maliyeti gibi ölçütleri göz önünde bulundurularak risk sermayesi kararı alınabilmesi, kripto para birimlerinin fiyat ve işlem miktarındaki istikrarsızlık ve ani dalgalanmaların önceden tahmin edilmesi, şirketlerin finansal tablolarına dair makul bir güvence verilebilmesi ve yapılan usulsüzlüklerin tespiti, finansal krizin öngörülmesi makine öğrenmesi ile mümkün olmaktadır.

Çalışmanın ilk bölümünde, Endüstri 4.0 ve makine öğrenmesi, veri madenciliği ve makine öğrenmesi tekniklerinden bahsedilmiştir. Çalışmanın ikinci bölümünde ise bu çalışmanın amacı olan makine öğrenmesinin finansman ve muhasebe alanındaki uygulamalarının incelenmesine yer verilmiştir. Bu kapsamda, makine öğrenmesinin finansman ve muhasebe uygulamaları üzerindeki etkisi ve finansman ve muhasebe alanlarındaki dönüşüm detaylı bir biçimde açıklanmıştır.



### 1.1. ENDÜSTRİ 4.0 VE MAKİNE ÖĞRENMESİ

Endüstri 4.0 terimi ilk defa Almanlar tarafından 2011 yılında kullanılmış olup 4. Sanayi Devrimi dönemini ifade etmektedir. Dijital teknolojilerin gündeme gelmesiyle bilgisayardan öte “Yapay Zeka” öne çıkarak; hem siber sistemlerin hem de gerçeğin birbirleriyle entegre çalışabilmesi ile yeni bir çağa tekabül etmektedir. Sanayi Devrimi'nin dördüncü aşamasında bulunduğu için sanayi faaliyetlerinin de değiştiği bu yeni çağa “Endüstri 4.0” tanımlaması yapılmıştır. Dijital teknoloji yapısının arka planında veri bulunmaktadır. Bir yerden bir yere veri aktarımı sağlanıyorsa, o verilerin işlenerek anlamlı hale getirilmesi, veriden bilgiye giderek anlamlı bir hale getirilmesi ve işlenerek iş zekası, veri analitiği gibi araçlar sayesinde yapılan anlamlı çıkarımlarla iş yapış modellerinin çok daha etkinleştirilmesi süreci gerçekleşmektedir. Bu bağlamda, dijital teknolojilerin asıl başlangıç noktası veridir. Yapay zeka, bilgisayarların insanın bilişsel süreçlerine benzeyen bir biçimde algılama, öğrenme, düşünme, iletişim kurma ve karar vermesini sağlayan becerilerin bütünüdür. Yapay zeka verinin alınıp işlenerek daha önce tanımlanmış olan kodlar ile değerlendirilme yapılması ve sistemin çalıştırılmasıdır. Bir başka deyişle, bilgisayarların insanlar gibi düşünmesini sağlamaktır.

İlk yıllarda makine öğrenmesi sistemleri sadece kendisinden daha geniş bir sistemi ifade eden yapay zekanın bir parçası olarak görülmüştür. Zaman içerisinde makine öğrenmesinin uygulama alanı çok genişlemekte ve yapay zeka çerçevesine bağlı olarak tanımlanan dar sınırların da ötesine geçmektedir. Kendi kendine hareket eden otonom araçlar yapay zeka sistemlerini kullanmaktayken, yakın bir kazayı tanımlayan otomatik görüş sistemi ise makine öğrenmesidir. Günümüzde çoğu insan akıllı telefonlarıyla konuşarak, telefonları ile senkronize edilmiş diğer uygulamalar ile günlük işlerini yürütebilmektedir. Akıllı telefon, kendisiyle konuşan bir insanın konuşma şekli hakkında daha fazla bilgi edinmekte ve zaman içerisinde hata yapma olasılığını da minimize etmektedir. Akıllı telefonun bir insanın konuşma şeklini öğrenme yeteneği bir yapay zeka örneğiysen, bunu gerçekleştirebilmek adına kullanılan o teknolojinin büyük bir parçasını da makine öğrenmesi oluşturmaktadır. Bu bağlamda makine öğrenmesi, modellerin edinilen tecrübeye dayalı olarak daha etkin çalışmasını sağlamak için çeşitli tekniklerin kullanılmasıdır. Yapay zeka ve makine öğrenmesi birbirleriyle derin bir ilişki içerisinde

olsa da makine öğrenmesi yapay zekadan kesinlikle farklıdır. Yapay zeka, makine öğrenmesini içerir fakat makine öğrenmesi yapay zekayı tam olarak tanımlamamaktadır (Gogas ve Papadimitriou, 2021).

Makine öğrenmesi yapay zekanın aşağıdaki görevleri gerçekleştirmesini sağlamaktadır:

- Orijinal geliştiricisinin öngörmediği yeni koşullara uyum sağlamak,
- Her türden veri kaynağının kalıplarını tespit etmek,
- Tespit edilmiş olan kalıplara göre yeni davranışlar oluşturmak,
- Oluşturulan yeni davranışların başarısına ya da başarısızlığına yönelik kararlar almak.

Makine Öğrenmesi (ML) terimi ilk defa Arthur Samuel tarafından esas olarak öncü olan Yapay Zeka (AI) sistemlerinin bir parçası olarak görülen ve güçlü bir “öğrenme” sağlayan bir modelin tanımlayıcısı olarak kullanılmıştır. Karmaşık örüntüleri algılayıp verilerden öğrenim sağlamak ve zaman içerisinde doğruluğunu da aşamalı olarak artıran uygulamalar ortaya çıkarmaya odaklanmaktadır. Makine öğrenmesinin temeli matematiktir. Algoritmalar, büyük verilerin yorumlanma şeklini belirlemektedir yani girdilerin belirli şekillerde işlendiğini ve veri modellerine dayalı olarak öngörülebilir çıktılar oluşturmasını sağlamaktadır. Öngörülemeyen şey verinin kendisidir. Yapay zekaya ve makine öğrenmesine duyulan ihtiyacın sebebi, anlamlandırabilmek amacıyla verileri deşifre etmektir.

Makine öğrenmesi, bilgisayar biliminin ve istatistiğin kesiştiği zaman ortaya çıkan doğal bir sonuç olmaktadır. Bilgisayar bilimi mevcut problemlerin nasıl çözülebileceğini ve hangi problemlerin kolay kontrol edilip hangilerinin izlenemez olduğunu vermektedir. Yani, algoritma, hesaplama makinelerini ve kendisiyle ilgili bilgilerin incelenmesini konu edinmektedir. İstatistik ise, verilerden ve bir dizi modelden ne çıkarılabileceğini ve bu çıkarımların ne derece güvenli olacağını konu edinmektedir. Makine öğrenmesi, hem bilgisayar bilimini hem de istatistiği içine alan her iki konuya da dayanmaktadır. Ancak aralarında temel farklar olduğu da unutulmamalıdır. Bilgisayar bilimi, bilgisayarların manuel olarak nasıl programlanacağına dayanırken, makine öğrenmesi

ise bilgisayarların kendilerini nasıl programlayacakları sorusuna dayanmaktadır. İstatistik esas olarak verilerden hangi sonuçların çıkarılabileceği konusuna dayanmaktayken makine öğrenmesi bu verileri en etkin şekilde çıkarmak, depolamak ve birleştirmek için hangi hesaplama yöntemlerinin ve algoritmaların kullanılabilceğini ve birden fazla öğrenme görevinin nasıl yapılabilceği sorularına dayanmaktadır. Makine öğrenmesiyle bağlantılı olan bir diğer alan ise psikolojidir. Psikoloji, zihnin süreçleri ve davranışların neden olduğuna ilişkin tanımlamalar yapmak için davranışı ya da zihni inceleyen sosyal ve aynı zamanda doğa bilimidir. Organizmaların hem bilinçli hem de bilinçsiz olarak gözlenen davranışları; ayrıca düşünme, zihinde canlandırma, hatırlama ve hayal etme gibi doğrudan gözlemlenemeyen davranışlarını izleme psikolojinin alanına girmektedir.

Makine öğrenmesinde de makinelerin nasıl öğrenebileceği, insanların ya da hayvanların nasıl öğrendiği sorusuyla iç içe geçmiş cevaplara sahiptir. Makineler ve insanlar tamamen farklı biçimlerde öğrenme eylemini gerçekleştirmektedir. Makinelerin rutin görevleri insanlara kıyasla çok daha hızlı bir şekilde ve genellikle hatasız yerine getirmesine rağmen insanların düşünme ve fikir üretme süreçlerini de hala gerektirmektedir. Yapabileceği şey, tahmine dayalı analitiği herhangi bir insanın yapabileceğinden çok daha hızlı gerçekleştirmektedir. Bu durum, insanların daha verimli çalışmasına yardımcı olmaktadır. İnsanlar yapay zeka ve makine öğrenmesinin yapabileceklerinin getireceği sonuçları gerek ahlaki ve gerek etik kararların alınabilmesi için düşünmek zorundadır (Mueller, Massaron, 2021).

Makine öğrenmesi, istatistiği de içine almaktadır fakat aralarındaki hedef farklılıklarından doğan temel farklar aşağıdaki tablo ile gösterilebilir:

Teknik	İstatistik	Makine Öğrenmesi
Veri İşleme (Data Handling)	Modeller, küçük veriler için tahmine dayalı bir güç yaratmak için kullanılmaktadır.	Bağlantı ağları ve grafikler gibi büyük veriler ile çalışmaktadır.
Veri Girişi (Data Input)	Parametreler, gerçekteki olayları yorumlamaktadır.	Yeni verilerin tahmininde doğruluğu en üst düzeye çıkarmak için örnekleme, rastgele hale getirme ve dönüştürme yapılmaktadır.
Sonuç (Result)	Çıktılar, parametrelerin değişkenliğini ve belirsizliğini göz önüne almaktadır.	En ideal tahmine varmak ya da verilmesi gereken kararın ne olacağına ilişkin olasılık dikkate alınmakta ve kıyaslanmaktadır.
Varsayımlar (Assumptions)	Belli bir çıktı varsaymakta ve bunu kanıtlamaya çalışmaktadır.	Verilerden öğrenmektedir.
Dağıtım (Distribution)	İyi tanımlanmış ve belli bir dağılım varsaymaktadır.	Verilerden öğrenmeden önce bilinmemektedir ve yok sayılmaktadır.
Öğrenme (Fitting)	Sonuç mevcut veri dağılımına uygundur.	En uygun ama genel manada bir model yaratmaktadır.

**Tablo 1:** Makine öğrenmesinin teknik ve istatistik farklılıkları.

**Kaynak:** John Paul Mueller, Luca Massaron. ‘*Machine Learning*’, s. 47, 2021.

Makine öğrenmesi işletmeler için köklü bir değişim ve rekabet avantajı sağlayan unsur olarak kabul edilmektedir. Makine Öğrenmesi, yatırım bankalarının büyük veri setlerini normalden daha yüksek hızlarda işleyip; hisse, türev ürünlerin alım satımı gibi çeşitli otomatik işlem faaliyetleri için anında tahminler yapmasına olanak sağlamaktadır. Makine öğrenmesi, bankaların ipotek, kredi ve müşteri hizmetleri gibi önemli süreçleri otomatikleştirmesine yardımcı olur; örneğin, Bank of America sohbet robotu, müşterilerin günlük bankacılık işlemlerini gerçekleştirmelerine yardımcı olurken finansal yönetimi iyileştirme konusunda temel bilgiler sunmaktadır (*Bank of America, 2019*).

### 1.1.1. VERİ MADENCİLİĞİ

Teknolojinin gelişmesi ile birlikte çok sayıda verinin depolanması, verilerin işlenmesi, hızlı ve etkin algoritmalar ile sonuçlara ulaşma imkanı doğmuştur. Makine öğrenmesinde algoritmalar da, güncel ve yeni verilere dayanan kararlar ve tahminler yapmak için çok sayıda veriye ihtiyaç duymaktadır. Algoritma ne kadar başarılı olursa, daha çok sayıda verinin işlenmesi

mümkün olup, o verilerden anlamlı bilgiler edinilmesiyle birlikte yapılacak olan tahminler ve alınacak olan kararlar o kadar doğru olacaktır. Makine öğrenmesi algoritmaları geçmişteki verileri de kullanarak veri için en uygun modelleri ortaya çıkarırlar ve yeni gelen verileri de bu modele göre analiz ederler. Bu noktada, çok sayıda verinin sebep olabileceği karmaşıklığı ortadan kaldırmak adına verilerin içinden sadece işe yarayacak olan verilerin bulunup ayrıştırılmasını yani veri madenciliği (*data mining*) görevini de yerine getirir. Çok sayıda anlamsız verinin işlenmesi-verinin büyüklüğüne göre-günler hatta aylar sürebilmektedir. Veri madenciliği, çok sayıda verinin arasından faydalı bilgiye ulaşmayı amaçlamaktadır ve bu işlem zaman tasarrufu konusunda da avantaj sağlamaktadır. Zamandan tasarruf etmek beraberinde maliyetlerin azaltılmasını da sağlamaktadır. Bu nedenle veri madenciliği; tıp, ekonomi, bankacılık, finans, muhasebe gibi birçok alanda kullanılabilir (Ertuğrul ve diğerleri, 2012).

## 1.2. MAKİNE ÖĞRENMESİ TEKNİKLERİ

Büyük işletmeler tarafından kullanılan üç ana makine öğrenmesi uygulaması kümeleme, sınıflandırma ve tahmindir (Lee, Shin, 2020).

### 1. KÜMELEME (CLUSTERING)

Kümeleme uygulaması birbirlerine benzeyen örneklerin gruplandırılması için kullanılmaktadır ve denetimsiz makine öğrenmesi olarak kabul edilmektedir. Çünkü nesnelerin sınıf etiketleri henüz bilinmemektedir. Yapılan kümeleme analizi, grupların modellerini göstermektedir ve elde edecek verimliliğe ilişkin öngörü sağlamaktadır. Yani iş operasyonlarına dair verilecek kararlar için en iyi uygulamaları belirlemektedir. Örneğin, kişiselleştirilmiş ürün ya da hizmet önerilerinde bulunulabilmesi amacıyla bir şirketin birbirleriyle ortak özellikleri olan müşterilerini gruplayabilir. Bu da müşteri memnuniyeti artışını sağlamak noktasında etkili olacaktır. Örneğin, bir dijital medya platformu dünyanın her yerinden olan müşterilerini benzer film ve dizi tercihlerine göre gruplandırmak ve onlara kişiselleştirilmiş deneyim sunabilmek için kümeleme uygulamasını kullanmaktadır (Najafabadi ve diğ., 2017). Ayrıca, kümeleme yöntemi tüketicinin satın alma davranışını da inceleyerek ve diğer bazı kriterleri de göz önünde bulundurarak bir perakende mağazası içindeki yerleşim düzenine karar vermek amaçlı da kullanılmaktadır (SAS, 2011).

## II. SINIFLANDIRMA (CLASSIFICATION)

Sınıflandırma, bir gözlemin kategorisini ya da sınıfını belirleme sürecidir. Nesnelere kategorileri kümelemenin aksine zaten daha önceden bilinmektedir. Örneğin, kredi başvurusunda bulunan bir kişiye kredi verilip verilmeyeceği yönünde karar alınması için sınıflandırma yöntemiyle makine öğrenmesi uygulaması geçmiş kredilerini geri ödeme ve temerrüt verileri kullanarak yardımcı olabilmektedir. Bu durum bankaların müşterilerine daha etkili bir hizmet vermesi için fırsat yaratmaktadır. Aynı zamanda perakendecilerin kişiselleştirilmiş müşteri hizmetleri deneyimi sunmak için büyük miktarlarda müşteri profili verilerini analiz etmelerine olanak tanımaktadır. Sınıflandırma, farklı iş süreçlerinde eşgüdüm sağlamak amacıyla da yardımcı olmaktadır. Örnek olarak bir lojistik şirketi düşünüldüğünde sürücüler için daha iyi rotaların belirlenmesi için bir makine öğrenmesi sınıflandırıcısı kullanılabilir. Sınıflandırıcı, sürücülerden gelen girdileri dikkate alarak hangi teslimat güzergahının maliyet azaltılmasını yaratıp zamanın etkin kullanımını sağladığını ve bu sayede müşteri memnuniyetini en üst düzeye çıkardığını belirlemek için o girdileri birleştirebilmektedir (Lee, Shin, 2020).

## III. TAHMİN (PREDICTION)

Makine öğrenmesi girdileri belirlemek ve onları gelecekteki olayları tahmin etmek için kullanılmaktadır. Tahmin, gelecekte ne olacağının öngörülebilmesi için kullanılmaktayken sınıflandırma mevcut durumla ilgili bir denklem çıkarmak için kullanılmaktadır. Tahmine dayalı bir makine öğrenmesi işletmenin gelecekte muhtemel pazar performansını etkileyecek olan durumları saptamak için verileri kullanabilmektedir. Bankacılık sektöründe makine öğrenmesi her zaman finansal hizmetler ve otomasyon için en uygun stratejileri geliştirmektedir. Bu nedenle, bankacılık sektöründe de işlemlerin yürütülmesinin daha otonom hale getirilmesi için bir alternatiftir. Depo yönetiminde bir depoda kullanılan makinelerin ne zaman bakıma ihtiyaç duyabileceklerini tahmin etmek için de kullanılmaktadır (Lee, Shin, 2020).

### 1.2.1 DESTEK VEKTÖR MAKİNELERİ (SUPPORT VECTOR MACHINE)

Destek vektör makineleri genel anlamda makine öğrenmesinde sınıflandırma problemlerinde kullanılan gözetimli yöntemlerden biridir. Bu nedenle de destek vektör makinelerinin çıkış amacının sınıflandırma olduğu söylenebilmektedir (Muller, 2020).

Destek Vektör Makinelerinin bazı kısıtlamaları da mevcuttur:

- Çok fazla sayıda özelliğin meydana gelmesiyle veri kümesinin doyması,
- Genişletmenin çok sayıda aşırı uyuma neden olan gereksiz özellik yaratması,
- Sınıfların genişleme düzeyinin belirlenmesindeki güçlük ve dolayısıyla doğrusal olarak ayrılabilir hale getirmenin güçlüğüdür (Mueller, Massaron 2021).

### 1.2.2. DOĞRUSAL REGRESYON (LINEAR REGRESSION)

Doğrusal regresyon, istatistikte bağımlı ve bağımsız değişkenler arasındaki ilişkiyi modellemeye yönelik olan doğrusal bir yaklaşımdır. Doğrusal regresyon, makine öğrenmesinde çok önemli bir rol oynamaktadır. Doğrusal regresyon algoritması göreceli olarak daha basit, kullanışlı ve özelliklerinin iyi biliniyor olması sebebiyle denetimli makine öğrenmesinin en temel algoritmalarından biri olarak karşımıza çıkmaktadır.

#### **Doğrusal regresyon yaklaşımının kullanım alanları:**

Değişkenler arasındaki olası ilişkileri tanımlamak için yaygın olarak kullanılan bir yaklaşımdır. Finans, ekonomi, biyoloji, sosyal bilimler gibi bazı disiplinlerde kullanılan en önemli araçlardan biridir.

- Doğrusal regresyon, finasta bir yatırımın riskini analiz etmek ve ölçmek için kullanılmaktadır. Yatırımın getirisiyle tüm riskli varlıkların getirisiyle ilişkilendirmektedir.
- Ekonomide deneysel bir araç olarak sıkça kullanılmaktadır. Örneğin, sabit yatırım harcamaları, stok yatırımları, bir ülkenin ithalatını ve ihracat harcamalarını, likit varlıklarını tutma talebini, işgücü talebini tahmin etmek için kullanılabilir.

### 1.2.3. SİNİR AĞLARI (NEURAL NETWORK)

Büyük miktarda veri arasındaki ilişkileri tanımlamak için bir insan beyninin süreçlerini örnek alan ve taklit eden bir dizi algoritmadır.

### 1.2.4. NAİVE BAYES ALGORİTMASI (NAİVE BAYES ALGORITHM)

Naive Bayes algoritması, olasılık ve koşullu olasılıktan faydalanarak girdilerin ait oldukları sınıfları bularak sınıflandırma yapan görece basit bir uygulama olarak görülmektedir. “*Bayesian*” karar kuramını esas almaktadır ve temel olarak en yüksek olasılığa sahip olan kararın seçilmesine yardımcı olmaktadır. Verinin az sayıda ya da çok sayıda olması önem arz etmemektedir. Üstünde durulması gereken en önemli konu girdi verisinin en uygun şekilde hazırlanması gerektiğidir.

### 1.2.5. LOJİSTİK REGRESYON (LOGISTICS REGRESSION)

Lojistik regresyon, ilk defa Cox tarafından önerilmiş olan (Andersen, 1994) herhangi bir aralığın değerini almakta fakat sadece sıfır ile bir arasındaki değerleri vermektedir. Lojistik regresyon sayısal veri değerlerinde daha iyi sonuç verir, ancak değişkenlerin karışık olarak tahmin edilmesine izin verir. Bağımsız değişkenlerde neden sonuç ilişkisini belirlemede faydalanılan bir yöntemdir. Doğrusal regresyon modelinden ayrıldığı nokta lojistik regresyondaki bağımlı değişkenin minimum iki düzeyli olmasıdır. Kullanılabilirliğinin olduğu çok sayıda uygulama mevcuttur.

### 1.2.6. KARAR AĞACI (DECISION TREE)

Karar ağacı sınıflandırma algoritmaları, yapay zekada makine öğrenmesi için kolay anlaşılır bir yapıya sahip olduğundan yaygın olarak kullanılmaktadır. Karar ağacı adı verilen bu yaklaşım “böl ve yönet” mantığına dayanmaktadır.

Karar ağacında verinin sınıflandırılması iki işlemde gerçekleştirilmektedir. Birinci basamak öğrenme basamağıdır. Öğrenme basamağında sınıflandırma algoritması tarafından önceden bilinen bir eğitim veri analiz edilerek model oluşturulur. Öğrenilen bu model, sınıflama kuralları olarak ya da karar ağacı olarak gösterilir. İkinci basamak olan sınıflama basamağında ise test verisi, karar ağaçlarının veya sınıflama kurallarının doğruluğunu belirlemek amacıyla kullanılır ve kabul edilebilir bir oranda doğruluk oluyorsa kurallar yeni verilerin sınıflandırılması için kullanılır (Bilekdemir, 2010: 25).



### 1.2.7. K - ORTALAMALAR ALGORİTMASI (K - MEANS)

K-Means algoritması kümeleme için yaygın olarak kullanılan denetimsiz öğrenme yöntemlerinden biridir. (Lloyd ve diğerleri, 2005). Çok yaygın olmasının ana sebepleri arasında uygulamadaki basitliği ve verimliliği bulunmaktadır. Denetimsiz öğrenme kategorisinde olan bu algoritma, genellikle veri madenciliğinde örüntü tanıma ve veri ön işleme alanlarında kullanılmaktadır (Kazaz, 2019).

## 2.1. FİNANSAL BİR ARAÇ OLARAK MAKİNE ÖĞRENMESİ

İlk defa bir makalede (Wang, 1984) aslında yapay zeka teriminin benimsenmiş olmasına karşın günümüzde yapılan ayrıma göre yapay zekadan daha çok makine öğrenmesinin ekonomi problemi üzerinde uygulandığı görülmektedir. 1988'de White, IBM'in günlük hisse senedi getirilerini tahmin etmek amacıyla Sinir Ağları (Neural Network) algoritmasını içeren bir makale yayınlamıştır. O zamandan beri, makine öğrenmesinin ekonomide varoluşu da istikrarlı bir şekilde artmıştır. Başlangıçta, çok sayıda verinin olduğu finansal zaman serilerinin tahmin edilmesinde kullanılmaktaydı. Fakat o dönemdeki bilgisayarların işlem gücünün, yazılımların ve donanımların kapasiteleri görece düşük olduğu için eğitim çok fazla zaman almaktaydı. Günümüzde, bilişim sistemlerinin de gelişmesi ile birçok makine öğrenmesi algoritması ekonomik tahminlerde çok başarılı olmaktadır (Gogas and Papadimitriou, 2021).

Diğer alanlar gibi finansal piyasalar da bilimin ve teknolojinin gelişmesi ile sürekli değişmeye ve dönüşmeye teşvik edilmektedir. Makine öğrenmesinin finansman alanında kullanılmasıyla beraber maliyetlerin azaltılması ve risklerin makul düzeylerde olması sağlanmaktadır. Finansal piyasaların ve sistemlerin işleyişinin analiz edilmesi ile ülkelerin de ekonomik işleyişi hakkında tahminlerde ya da öngörülerde bulunulabilmektedir. Bu sayede, ekonomik dalgalanmalar kontrol altında tutulabilmekte ve sürdürülebilirliğe önem verilebilmektedir.

Ryll ve Seidens (2019) hazırlamış oldukları yedi ana parametreden oluşan tabloda finansal piyasaların tahminine makine öğrenmesinin uygulandığını varsayarak yüz elliden fazla makaleyi inceleyerek bu makalelerde yapılan deneyleri açıklamışlardır. Araştırmaya konu olan makalelerin performans ölçütlerine dayanarak, farklı algoritmalar karşılaştırılarak performanslarının analiz edilmesi için sıralama analizi de yapılmıştır. Yapılan analiz sonucunda makine öğrenmesi algoritmalarının finansal piyasa tahmininde geleneksel yöntemlerden daha başarılı bir performans ortaya koyma eğiliminde olduğu görülmüştür.

Sadgali ve diğ. (2019), finansal sisteme ciddi manada tehditler oluşturan finansal dolandırıcılıktan bahsederek, finansal kuruluşların dolandırıcılık saptama sistemini durmaksızın iyileştirmek zorunda olduğunu belirten çalışmalar yapmışlardır. Yaptıkları birçok çalışmada makine öğrenmesinin ve veri madenciliğinin finansal dolandırıcılık için çözüm üretme fonksiyonundan bahsetmişlerdir ve bugüne kadar finansal dolandırıcılığı önlemek adına başarılı olan teknik ve yöntemleri tanımlamışlardır.

Henrique ve diğ. (2019), bibliyografik tarama yöntemi ile elli yedi farklı metni inceleyerek ve değişik biçimlerde sınıflandırmalar yaparak finansal piyasaların fiyatlarının tahmin edilmesini sağlayabilmek için model aramışlardır. Finansal piyasada fiyatların tahmin edilmesinde en güncel tahmin tekniği olarak araştırılan tekniğin makine öğrenmesi modelleri olduğunu belirtmişlerdir. Tahminleme yapmak için Destek Vektör Makineleri (SVM) ve Sinir Ağları (Neural Networks) en yaygın kullanılan modeller olmuştur (Yılmaz, 2019).

Soybilgen ve Yazgan (2020) ağaç tabanlı modellerin kullanımı ile Ocak 2000 ile Aralık 2018 yılları arasındaki ABD'nin gayri safi yurt içi hasılasını tahmin etmeye çalışmışlardır. Bu çalışma için yüzden fazla sayıda finansal ve makroekonomik değişken içeren büyük ölçekli bir veri setini kullanmışlardır.

Yoon (2020), "Rassal Orman (Random Forest)" algoritmasını kullanarak 2001'den 2018'e kadar olan yıllar için Japonya'nın gayri safi yurt için hasılasına dair tahminlerde bulunmuştur. Çalışmayı yaparken de Uluslararası Para Fonu ve Japonya Bankası'nın tahminlerini karşılaştırma ölçütü olarak kullanmıştır. Örneklem dışı tahmini iyileştirmek adına optimum hiper parametreleri seçmek için tasarlanan çapraz bir doğrulama süreci kullanmıştır. Bu makroekonomik tahminlerde makine öğrenmesi modellerinin kullanımının artırılmasını teşvik eden bir çalışmadır.

Chen ve diğ. (2017) bir kripto para birimi olan Bitcoin'in fiyatını belirleyen unsurları belirlemek için Garch modeli ile beraber Karar Ağaçları ve Destek Vektör Makineleri'ni de kullanarak çok yönlü tahmin geliştirmiştir. Çalışmalarındaki bulguları Bitcoin, Ethereum, Litecoin ve diğer kripto para birimlerinin özellikle günlük fiyatına bakıldığında aşırı volatilitate sergilediği gösterilmektedir. Volatilitate endeksi genellikle finansal aracın belirli bir zaman aralığındaki riskini ölçmektedir, yani piyasalarda korku

endeksi olarak adlandırılmakta ve piyasaların oynaklığını ölçmektedir. Bu da yatırım yapmak ya da teknoloji piyasalarına girmek isteyen, risk arayan yatırımcılara uygun olmaktadır. Çalışmanın sonuçları bu noktada finans kurumlarına yardımcı olabilmektedir. (Gogas ve Papadimitriou, 2021.)

Bouri ve diğ. (2020) ise ABD-Çin ticaret savaşı sonrası için Bitcoin'i riskten korunma seçeneği olarak araştırmıştır. Bitcoin'in dünya hisse senedi endeksleri, tahviller, petrol, altın, genel emtia endeksi ve ABD doları endeksi için güvenli bir liman olup olmayacağını incelemeyi amaçlamaktadır.

Yılmaz ve Arabacı (2020), üç farklı döviz kurunu tahmin etmek için on farklı makine öğrenmesi modeli arasında kapsamlı bir araştırma yapmış ve hibrit bir modelin rekabette daha iyi bir performans gösterdiği sonucuna varmışlardır.

Buna benzer şekilde, Chakraborty ve diğ. (2020) ise yedi farklı ülkenin işsizlik oranının tahminini yapmak için iki farklı modeli birleştirerek yeni bir hibrit yöntem önermişlerdir. Farklı metodolojileri kullanan farklı tahminler ile tek bir tahminde birleştirmişlerdir. Bu sayede ekonomik öngörüye ve muhakemeye gereksinim duyulan istatistiksel tahminin aksine, birleştirilmiş tahmin çok daha kolay seçimler içerdiğinden dolayı daha avantajlı olmaktadır.

Duarte ve diğ. (2020) Brezilya borsasındaki finansal başarısızlığı tahmin etmek için finansal haberlerin ve geçmiş fiyatların tahminini birleştirmiştir. Çalışmalarında makine öğrenmesi ve yapay zeka konularının zaman içerisindeki evrimine odaklanmış ve finansal stres, kredi notu, iflas, kredi riski gibi konularda farklı bakış açılarıyla değerlendirmeler sunarak çeşitli akademik araştırmaları değerlendirmek için sistematik bir inceleme yapmışlardır.

Tsagris (2020), PCHC adı verilen yeni bir öğrenme algoritması geliştirmiş ve bu algoritma değişkenler arasındaki ilişkilerin öğrenilmesi ve ardından nedensel yönlerini atayan ve skorlama aşamasından oluşan hibrit bir algoritma olarak hem kredi kartı harcamalarını hem de gelir seviyesini içermektedir.

Triebels ve diğ. (2020), Meksika'nın bankacılık sektöründen alınan veriler ile Sinir Ağları "Neural Networks" algoritması ile bankaların likidite ihtiyaçlarını formüle etmiştir.

Lussange ve diğ. (2020), her hisse senedinin pekiştirmeli öğrenmeyi kullanarak özgün bir şekilde hareket ettiği çok yönlü bir borsa simülasyonu oluşturmuş ve test etmiştir.

Ulusal, uluslararası ve küresel işletmeler zaman içerisinde rekabetin de artması ile rakiplerine karşı bir rekabet üstünlüğü sağlayarak kendileri için bir avantaj yaratabilmek ya da değişen, dönüşen ve gelişen zamana kendilerini adapte edebilmek için veya meydana gelebilecek ekonomik risklere karşı önceden risk yönetimi yöntemlerini kullanarak yeniden yapılandırma faaliyetlerine odaklanmaktadır. İşletmelerin sürdürülebilir olması, belirsiz ve farklı bir rekabet ortamında nasıl hayatta kalabileceklerini iyi bilmeleri ve risk yönetimini oldukça etkili bir şekilde gerçekleştirmeleri önemlidir. Rekabet ortamlarında hayatta kalmak için en büyük etkiye sahip olan en önemli faaliyetlerden biri risk yönetimleri için kullanılacak araçları tanımlamaktır. Her sektörün taşıdığı riskler kendilerine özgü olsa da işletmelerin başlıca risk türleri çevresel, organizasyonel ve finansal riskler olmak üzere incelenebilmektedir. Döviz kurları, faiz oranları, emtia fiyatları ve kredi risklerindeki değişikliklerden kaynaklanan riskler finansal riskler olarak kabul edilebilmektedir (Smith ve Stulz 1985; Fatemi ve Glaum, 2000).

Günümüzde hala gelişmekte olan küresel iş uygulamaları ile şirketler özellikle değişken döviz kurları, faiz oranları ve emtia fiyatları gibi finansal ve ekonomik konular ile bağlantılı olarak farklı biçimlerde oldukça risk taşımaktadır. Finansal başarısızlık, bir işletmenin finansal yükümlülüklerini yerine getirememesine, ödeme yapamamasına ya da çok güç bir şekilde karşılayabilmesine neden olan bir durumdur. İşletmelerin varlıkları ile borçları doğru yönetilmediği takdirde ortaya çıkmaktadır. Bu konu iç denetçiler için çok fazla önem arz etmektedir çünkü adı geçen işletmenin sürdürülebilirliği hakkında iç denetçilerin makul bir güvence verebilmesi gerekmektedir. Mali başarısızlığa ilişkin iç denetim tarafından sağlanan güvence tüm paydaşlar için önemli olmaktadır. Bu nedenle şirketler risk yönetimi için kullanılacak araçları tanımlamalıdır. Bu araçlar yapay zeka ve makine öğrenmesi olarak tanımlanabilmektedir.

Denetim faaliyetlerinde makine öğrenmesi kullanımı iç denetçilere karar verme noktasında yardımcı olmaktadır. Finansal başarısızlık konusunda makine öğrenmesi ve makine öğrenmesinin ‘‘Sinir Ağları’’, ‘‘Destek Vektör Makineleri’’, ‘‘Karar Ağaçları’’ gibi algoritmaları 1990’lı yıllardan bu yana kullanılmaktadır. Makine öğrenmesinde herbir algoritmanın güçlü olduğu yönler ve zayıf olduğu yönler bulunmaktadır. Destek Vektör Makineleri (SVM) ve Sinir Ağları (Neural Network) algoritmaları bir şirketin iflas edip etmeyeceğine dair finansal başarısızlığı belirlemede en çok kullanılan algoritmalarlardır.

İşletmelerde ekonomik olayların ispatlanma yükümlülüğü bulunmaktadır. Teknolojinin gelişmesiyle günümüzde ekonomik olayların belgelendirilmesi ve doğrulanması yükümlülüğü, raporların dijital ortamlara geçişi ile bilgisayara önceden tanımlanan her şeyi sürece dahil eden makine öğrenmesi sayesinde finansal bilgi sistemi sürecin içine yerleştirilerek gerçekleştirilmektedir. Bu sayede, işletmelerin içerisindeki ekonomik olayları ölçen, kayıt eden, raporlayan muhasebe iş akışının çıktıları olan finansal tabloların oluşturulmasına katkıda bulunmaktadır.

Finans endüstrisi, çok değişkenli zaman serisi verilerinin analizinde öncülük eden bir geçmişe sahip olmasına karşın dijitalleşme alanındaki son gelişmeler bu sektördeki işletmeler için mevcut olan verilerin hem miktarını hem de türünü genişletmiştir. Artık birden fazla zaman ölçeği ve organizasyon düzeyinde düzensiz aralıklarla gerçekleşen zengin olay akışları klasik zaman serilerine katılmaktadır ve akışlar çoğalmaktadır. Tek bir banka hesabı birden çok türde işlem etkinliği içerebilmektedir. Bir müşterinin çok sayıda hesabı, web sitesi etkileşimleri ve bunlara ek olarak kredi verileri olabilmektedir ve müşteriler hakkında çok önemli bir kararlar vermek farklı akışlardaki zamansal modellerin etkileşimini anlamaya bağlı olabilmektedir. Diğer endüstriler arasında, makine öğrenmesi yaklaşımları, verilerin biçimine ve yapısına göre uyarlanmış modeller oluşturmanın bir yolunu sunmuştur ve çeşitli görevleri çözmek için anlamlı sonuçlar çıkarmada başarılı olabilmektedir.

Çoğu sektörde yatırım kararları işletmelerin gelecek dönemde yaşayacağı operasyonel ve finansal performansı etkilemektedir. Geleceğin belirsiz olması sebebiyle yatırımlar da oldukça risk içermektedir. Bu belirsizliği azaltmanın yolu başarılı bir yatırım yönetimi ile yatırım değerlemesi

için ihtiyaç duyulan değişkenlerin tahmini de önemli olmaktadır. Satış gelirleri, maliyetler, yatırım harcamaları değerlendirme modellerinin temel bileşenlerini oluşturmaktadır ve enflasyon oranı ya da döviz kurları bu bileşenlerin zaman içerisindeki büyüme oranlarını ciddi anlamda etkilemektedir. Değerlendirmenin sonucu açısından enflasyon oranını ve döviz kurlarını tahmin etmek gerekmektedir. Yatırım kararları için yatırımın finansal olarak değerlendirilmesi gerçekleştirilmelidir. Yapılan bir araştırmada, makine öğrenmesinin algoritmalarından biri olan yapay sinir ağları (Neural Networks) ve Destek Vektör Makineleri (SVM) modelleri enflasyon ve döviz kuru gibi zaman serilerinin tahmininde kullanılabilir (Danas & Garsva, 2011).

Kurumsal faaliyetlerin toplam endeksinin hem örneklem içi hem de örneklem dışı gelecekteki piyasa getirileri için önemli bir tahmin gücüne sahip olduğunu ve ortalama varyanslı bir yatırımcı için çok daha fazla ekonomik kazanç sağladığı makine öğrenmesi yaklaşımları kullanılarak görülmüştür. Buna ek olarak, kurumsal endeksin tahmin etme yeteneğinin gelecekteki nakit akışları ve beklenen kurumsal yatırımlar hakkındaki bilgi içeriğinden kaynaklandığını ve kurumsal endeksin özellikle daha fazla bilgi asimetrisi olan hisse senetleri için iyi performans gösterdiği görülmektedir (Baranes, Amos & Palas Rimona, s.36-53, 2019).

### **2.1.1. MUHASEBE VE FİNANSMAN ALANINDA KARŞILAŞILAN ZORLUKLARA YÖNELİK MAKİNE ÖĞRENMESİ**

Makine öğrenmesinin zaman içerisindeki hızlı gelişimi, muhasebe ve finansman alanlarındaki geleneksel zorluklara yenilikçi çözümler sunmaya başlamıştır. Finans ve risk yönetimi alanlarında fiyatlandırma endüstrisindeki büyük bir zorluk olarak öne çıkmaktadır. Opsiyonlar, endüstride işlem gören bir finansal araç kategorisidir. Alıcıya bir ürünü belli bir fiyattan, belli bir tarihte alım ya da satım hakkını veren sözleşmelerdir. Opsiyonlar, kurumsal hisse senetleri gibi diğer finansal menkul kıymetlere dayandığından bir tür finansal türev olarak da adlandırılmaktadır.

Finansta ortalama opsiyonlar, risk yönetimi ve yatırım için şirketler, kurumsal yatırımcılar ve bireysel yatırımcılar arasında popülerdir çünkü ortalama opsiyonlar getirileri vade sonunda dayanak varlık fiyatlarındaki değişikliklere çok duyarlı olmamaktadır ve ucuz fiyat avantajına sahiptir. Buradaki zorluk, tekrarlayan pahalı hesaplamalar ve gerçekçi olmayan

model varsayımlarının dezavantajları ile birlikte geleneksel sayısal yöntemleri de beraberinde gerektirmesidir. Aritmetik ve geometrik ortalama seçeneklerini doğru ve özellikle hızlı bir şekilde fiyatlandırmak için bir makine öğrenmesi yöntemi gerekmektedir. Makine öğrenmesi bu zorluğu hem teoride hem de uygulamalarda çözmek için yeni ve etkili bir yöntem sağlamaktadır (Lirong, Wang, Yang 2020).

Opsiyon sahipleri, belirli bir tarihte üzerinde anlaşmaya vardıkları fiyattan ticaret yapma yükümlülüğü yerine hakkı elde etmek için bir prim yani bir opsiyon fiyatı ödemektedir. Dayanak varlığın yani sözleşmeye konu olan menkul kıymet ya da menkul kıymet endekslerinin mevcut fiyatı ve işlem fiyatı arasındaki fark, işlem tarihine kadar olan süre, dayanak varlığın volatilesi (oyunaklığı) opsiyon primini etkilemektedir. Avrupa tipi opsiyonlarının getirileri dayanak varlığın vade tarihindeki cari piyasa fiyatına bağlı olarak değişmektedir. Buna karşın, Asya tipi opsiyonlar

ise ortalama opsiyonların getirileri, dayanak varlığın vade tarihindeki ortalama fiyatına bağlı olmaktadır. Şirketler, kurumsal veya bireysel yatırımcılar risklere karşı korunmak ve ortalama opsiyonların avantajları sebebiyle yatırım portföyleri oluşturmak için yaygın olarak farklı seçenekler arasında ortalama seçenekler kullanmaktadır. Ortalama opsiyonlar, opsiyon getirilerini etkilemek için temel varlık karşılıklarını manipüle etmekten kaçınmaktadır. Ortalama bir opsiyonun getirisi, belirli bir dönemdeki dayanak varlığın fiyatlarının geometrik ya da aritmetik ortalaması olan ortalama fiyata bağlı olmaktadır. Bu noktada ortalama opsiyonların getirileri, uzun pozisyon sahibi taraf hakkının sadece vade bitim tarihinde borsa tarafından belirlenen zaman diliminde kullanılabilmesi Avrupa tipi opsiyonların aksine vade tarihi içinde sözleşmeye konu olan menkul kıymet ya da menkul kıymet endekslerinin dayanak varlık fiyatlarının değişmesine duyarlı değildir ve bu yüzden dayanak varlığın fiyatını manipüle etmek o kadar karlı olmamaktadır. Ayrıca, ortalama opsiyonların fiyatları dayanak varlığın vade tarihindeki piyasa fiyatına bağlı olan diğer opsiyonlara kıyasla nispeten ucuzdur çünkü ortalama varlık fiyatı riskinin vade tarihindeki varlık fiyatı riskinden görece düşük olmasıdır (Lirong ve diğ. 2020).

### 2.1.2. MUHASEBE VE FİNANSMAN ALANINDA MAKİNE ÖĞRENMESİ VE AÇIKLANABİLİRLİĞİ

Makine öğrenmesi tabanlı tahmine dayalı teknikler muhasebe ve finansman alanı dahil olmak üzere birçok alanda benimsenmektedir. Bununla birlikte, makine öğrenmesi tabanlı tahmine dayalı tekniklerin karmaşıklıkları nedeniyle tahminleri açıklamak ve doğrulamak genellikle zor olmaktadır. Bu durum makine öğrenmesinin ‘‘kara kutu’’ problemi olarak adlandırılmaktadır. Yapay Zeka (AI) ve Makine Öğrenmesi (ML) yöntemlerinin yorumlanabilirlik ve denetlenebilirlik özelliklerinin olmaması büyük bir riski ortaya çıkarmaktadır. Buna örnek olarak, ipotek temerrütlerini tahmin etmek için kullanılan bir makine öğrenmesi modeli yüzlerce büyük karar ağacından oluşabilmekte ve bu durumda da bu modelin sezgisel olarak nasıl çalıştığını anlamak güç olabilmektedir. Bu nedenle son zamanlarda makine öğrenmesi modellerini daha açıklanabilir yapmak için tartışmalar ortaya çıkmıştır. Geliştirilen açıklamalar, bir modelin işleyişine ilişkin farklı türden soruları yanıtlayabilmektedir (Bracke ve diğ. 2019).

Yapay zekanın işleyişinin insanlar tarafından net bir şekilde anlaşılabilmesi için makine öğrenmesi modellerinin açıklanabilir olması ve anlamlı ayrıntılar sağlaması gerekmektedir. Açıklanabilir makine öğrenmesinde bir diğer üzerinde durulması gereken nitelik verilere yorumlanabilirlik sağlamasıdır. Bu yorumlanabilirlik kişiyi modele ilişkin nihai bir karara götürürken itici güçleri anlayabilmesi manasına gelmektedir. Verilerin işlenebilmesi ve onlardan anlamlı çıkarımlar yapılarak bilgiye dönüştürülebilmesi için makine öğrenmesinin doğru bir öngörü sağlaması gerekmektedir. Buna ek olarak *Avrupa Komisyonu Yüksek Düzey Yapay Zeka Uzman Grubu (European Commission High-level Expert Group)* 2019 yılında güvenilir bir yapay zekayı tanımlarken etik yönergeler arasında sayılan yedi temel gereksinimden üçünü ‘‘açıklanabilir olması’’ niteliği ile ilişkilendirmiştir. Makine öğrenmesinin açıklanabilir olması ile insan faktörü ele alınmaktadır ve bu sebeple insan gözetimi öne çıkmaktadır. Şeffaflık ile yapay zeka ve yapay zekaya bağlı olarak alınan kararların bildirilmesi gerekmektedir çünkü kişilerin bir yapay zeka sistemi ile etkileşim içerisinde olduğunun bilincinde olması gerekmektedir. Hesap verilebilir olması ile yapay zeka sistemleri, denetlenebilirlik, algoritmaların değerlendirilmesi, veri ve tasarım süreçleri için mekanizmalar geliştirilmelidir.



Makine öğrenmesi ve açıklanabilirliği için makine öğrenmesi modellerini öngörücü çıktılarını açıklayabilen bir metodoloji önerilmektedir. Bu metodoloji herhangi bir makine öğrenmesi modelinin sonuçlarını işleyerek kara kutu modeline daha fazla içgörü, kontrol ve şeffaflık sağlamaktadır ve ekonomik bir dayanağı olan açıklanabilir bir yapay zeka yaklaşımıdır. Değişken katkıları da göz önüne almaktadır; yalnızca girdi nitelikleri ile değil aynı zamanda değişken katkıları ile de temsil edilmektedir. Açıklanabilirliğe giden yol açıklanabilir bir model geliştirmektir. Örnek olarak makine öğrenmesinin Doğrusal Regresyon (Linear Regression) ile Lojistik Regresyon (Logistics Regression) modellerinin yorumlanabilirlik oranı yüksek olmaktadır fakat tahmin doğruluğu sınırlı olmaktadır. Sinir Ağları (Neural Networks) ile Karar Ağaçları (Decision Trees) gibi modellerde ise makine öğrenmesi modelleri sınırlı bir yorumlanabilirlik sağlasa da tahmin doğruluğu daha yüksek olmaktadır. Bu bağlamda doğrusal regresyon modelleri, özellikle regresyon katsayılarının ekonomik anlamı olduğunda daha yorumlanabilir kabul edilmektedir. Örneğin yapay zeka yöntemleri ve makine öğrenmesi algoritmaları finans sektöründe sıkça kredi risk yönetimi alanında kullanılmaktadır (Giudici, 2018).

## 2.2. MUHASEBE VE FİNANSMAN UYGULAMALARI VE MAKİNE ÖĞRENMESİ



**Şekil 1:** Yapay Zeka ve Makine Öğrenmesinin Finansal Olarak Benimsenmesinin Arz ve Talep Faktörleri

**Kaynak:** *Artificial Intelligence and Machine Learning in Financial Services*, Financial Stability Board, s.9, 2017.

Yapay zeka ve makine öğrenmesi algoritmaları kredi kalitesinin değerlendirilmesi, sigorta sözleşmelerinin fiyatlandırılması ve pazarlanması, müşteri etkileşiminin otomatik hale getirilmesi gibi amaçlar için finans kuruluşları ve satıcılar tarafından kullanılmaktadır. Aynı zamanda makine öğrenmesi teknikleri ile finans kuruluşlarının sermayelerini organize etmelerinin yanı sıra riskten korunma ve alım satım işlemlerini optimize etmeleri de mümkün kılınmaktadır. Bu noktada, hem kamu hem de özel sektör kurumları tarafından veri kalitesinin değerlendirilmesi, mevzuatlara uyum sağlaması ve usulsüzlük tespiti için bu teknolojiler kullanılmaktadır.

### **2.2.1. KREDİ RİSK ANALİZİ VE TAHMİN UYGULAMALARI**

Ekonomik küreselleşmenin yaygınlaşması ve bilgi sistemlerin ilerlemesi ile beraber finans ve muhasebe alanlarında önem kazanan konulardan biri kredi riskinin nasıl yönetileceği olmuştur. İş başarısızlık oranının yaratacağı etkinin en aza indirgenebilmesi için finansal sıkıntıların öngörülebilirliğinin daha gerçek verilere dayanması gerekmektedir. Bir bankanın kendisinden kredi çekmiş olan müşterisinin krediyi geri ödemedeki temerrüde düşmesi durumunda yaşaması muhtemel olan finansal kaybın tahminine ilişkin olarak kredi risk modelleri kullanılmaktadır.

1999 yılında Mantegna ve Stanley tarafından tanıtılmış olan ve benzerlik ağları olarak da bilinen korelasyon ağları, varlık fiyatlarının zaman serilerinin korelasyon matrislerine göre gruplar halinde nasıl gruplandırılacağını göstermektedir. Bankalar arasında olan korelasyon kalıpları da bilanço verilerine dayalı özelliklerden çıkarılabilmekte ve kredi risk modellemesinde kullanılabilmektedir. Bussman, Giudici, Marinelli ve Papenbrock ise benzer ağların daha farklı bir kullanımından bahsederek, daha doğru bir öngörü ve açıklanabilirlik elde edebilmek adına ek özelliklerin istatistiksel bir öğrenme modeline dahil edilmesi ve yüksek performanslı bir makine öğrenmesi modeli önermektedir ve küçük ve orta ölçekli işletmelerin büyük bir kısmının kredi riskini tahmin etmek için önermiş oldukları yöntemlerini uygulamaktadır. Bu çalışmaların sonuçlarından edindikleri kanıtlar, standart bir Lojistik Regresyon modeline göre daha doğru bir tahmin modeli teşkil etmekte ve açıklanabilirlik ve yorumlanabilirlik niteliklerini geliştirdiklerini göstermektedir (Bussman ve Giudici. 2020).

Banka müşterisinin finansmanının teknolojinin gelişmesi ile beraber sürekli değişimi teşvik edilirken finansal kredi riskinin kontrol edilmesinin giderek zorlaşmasıyla riskler de beraberinde gelmektedir. Bir bankanın kredi verdiği bir müşterisine krediyi geri ödemede temerrüde düşmesi durumunda genellikle yaşanması beklenen finansal kaybın tahmin edilmesinde makine öğrenmesi teknikleri kullanılabilir. Makine öğrenmesi modelleri bu noktada finansal tablolarda yer almakta olan finansal bilgiler arasındaki doğrusal olmayan ilişkileri çıkarabilmektedir. Modeller, tahmine dayalı doğruluğu optimize etmek amacıyla seçilir. Finans alanında ise açıklanabilirliği ve doğruluğu dengeleyen modeller seçilmelidir (Murdoch ve diğerleri, 2019).

Yapılan araştırmalar makine öğrenmesinin finansal kredi riski üzerine başarılı bir tahmin etme becerisine sahip olduğunu göstermektedir. Geçmişteki çoğu finansal kriz, finansal piyasaların sistemik riskinin bireysel risk olmadığını, sistematik ve kapsamlı bir risk olduğunu anlamalarını sağlamıştır. Sistematik ve kapsamlı bir risk olması tek bir piyasanın ya da finans kuruluşunun çökmesi ile o riskin yayılarak diğer pazarlara veya kurumlara da ulaşması manasına gelmektedir. Tek bir piyasa ya da tek bir ekonomik varlığın sonuçlarına oranla sistemik riskin sonuçları daha ciddi boyuttadır (Ma ve Lv 2019).

Günümüzde mevcut olan riskin tespit edilmesindeki yöntemler ile sorunların üstesinden gelmek için makine öğrenmesi teknikleri kullanılarak doğru sonuçlar veren bir risk değerlendirme aracı sağlanması amaçlanmıştır. Müşterileri tanımak için oluşturulan uygulamaların verileri, bankalar için risk değerlendirme aracı olarak işlev görmektedir çünkü kredide temerrüde düşme olasılığı çok fazla olan müşterileri tanımlayarak onlar hakkında bilgiler sağlamak ve değerlendirme aracı olarak hizmet görmektedir. Bu bağlamda genel uyumu artırma ve yasal olmayan faaliyet riskini minimize etmek için şüpheli davranışlara odaklanmaktadır ve bankaların riski azaltmasına yardımcı olmaktadır. Ancak, müşterilerin adres bilgileri gibi verileri elde etmek kolay olmamaktadır. Elde edilen verilerin çok sayıda olması gibi nedenlerden dolayı üretilme hızı bakımından kaliteleri düşük olmaktadır. Veriler ve makine öğrenmesi teknikleri mevcut riski değerlendirmek için doğru bir araç olarak ortaya çıkmaktadır (Chen, 2019).

Kredi risk yönetiminde ortaya çıkması muhtemel olan risklerin ölçülebilmesi için açıklanabilir bir yapay zeka modeli önerilmektedir. Model, müşterilerin kredi puanlarını açıklamak ve müşterileri finansal özelliklere göre gruplandırarak gelecekteki davranışlarını tahmin etmek için kullanılacak tahminleri ortaya koymaktadır. Bir kredi riski modelinin en önemli bileşeni, kredi puanlama modelleri kullanarak istatistiksel olarak tahmin edilen temerrüt olasılığı olmaktadır. Açıklanabilir makine öğrenmesi modelleri, özellikle kredi riski olmak üzere finansal risklerin anlaşılmasını ve tahminini etkili bir şekilde geliştirebilmektedir (Bussmann ve diğ. 2020).

### **2.2.2. HIZLI TÜREV FİYATLANDIRMA**

Türev araçlar, faiz oranları, emtia fiyatları, hisse senedi, döviz kurları, kredi riski ve endekslerindeki değişimlere göre değer kazanan finansal araçlardır. Türevin kendisi iki ya da daha fazla taraf arasındaki bir sözleşmedir ve türev fiyatını dayanak varlığın değerlerindeki dalgalanmalardan almaktadır. Bir türevin fiyatı belirlenirken farklı fiyatlandırma modelleri kullanılmaktadır.

Günlük çok sayıda türev araçlarının fiyatlandırılması ve risk yönetimi göstergelerinin belirlenmesi gerekmektedir. Zaman ilerlediği ve piyasalar hareket ettiği için bu hesaplamaların çoğu kısıtlı bir süre için yararlı bilgiler sağlamakta ve bu nedenle hesaplanan değerlerin sürekli olarak güncellenmesi gerekmektedir çünkü türev araçlarının başarılı bir şekilde yürütülmesi için gerçek zamanlı güncellemeler ve bilgiler önem arz etmektedir. Son zamanlarda türev fiyatlandırma ve hesaplamaları hızlandırmak için çok fazla araştırma yapılmıştır fakat buna karşın çoğu kurum hala birtakım kısıtlamalar ile karşı karşıya kalmaktadır. Yapılan araştırmalar, bir hesaplama süresinin saniyeden daha kısa bir süre içerisinde gerçekleşmesinin mümkün olduğunu göstermiş olsa dahi bu işlemin binlerce opsiyon fiyatı ve binlerce alt değer için tekrarlanması gerektiğinden süreyi uzatabilmektedir. Bu da gerçek zamanlı değerlerin her zaman için mümkün kılınmasını zorlaştırmaktadır. Aynı zamanda, piyasanın faiz oranı, temettü getirisi gibi bazı parametreler ile sınırlı olması onu makine öğrenmesi teknikleri için ideal hale getirmektedir (Spiegeleer, 2018).

Jan de Spiegeleer ve diğ. yapmış oldukları çalışmada ayrıca Gauss süreç regresyonuna (GPR) dayalı makine öğrenmesi tekniklerini uygulayarak istenen hızlanmalara ulaşılabileceği gösterilmektedir. Gauss süreç

regresyonu (Gaussian Process Regression), verilen girdi özelliklerinden öğrenerek opsiyon fiyatlarının tahmininde kullanılan denetimli bir makine öğrenmesi algoritmasıdır. GPR'nin tek girdi değişkeni dayanak varlık fiyatı olmaktadır. Öğrenme sürecini hızlandırmakta ve hızlı türev fiyatlandırmayı sağlamakta ancak tolere edilebilir bir doğruluk kaybı da göstermektedir. Model, tahmin yeteneğinin hem fiyatlandırma hem de riskten korunma açısından diğer makine öğrenmesi modellerinden daha iyi performans gösterdiğini ve dolayısıyla tutarlı sonuçlar ürettiğini göstermektedir. Fakat hız konusunda istenen sonuca erişebilmek doğruluk oranının bir miktar azalmasına ancak yine makul ve kabul edilebilir sınırlar içerisinde kalmasına sebep olabilmektedir. Yapmış oldukları deneylerde eğitim seti ne kadar büyük olursa modelin o kadar güçlü olması ve dolayısıyla tahminlerin de doğru olduğu görülmüştür. Parametre sayısı ne kadar düşük ise sonuçlar da o kadar doğru olmaktadır.

Riskten korunmak ve uyumlaştırmak için türev fiyatlarının son saniyede alış-satış fiyat değişikliğinin makine öğrenmesi ile hızlandırılması yani temel fiyatlardaki değişikliklere hızlı tepkiler vermesi mümkün olmaktadır.

### **2.2.3. KURUMSAL PERFORMANSIN DEĞERLENDİRİLMESİ VE YATIRIM KARARLARI**

Performans analizleri, günümüzde artan rekabet koşullarında rekabet üstünlüğü kazanmak için şirketler tarafından yapılmaktadır. Küreselleşen piyasalarda şirketler performans ölçüm ve yöntemlerini daha fazla önemsemeye başlamışlardır. Bilhassa 1980'li yıllarda, yaşanan ekonomik durgunluk sebebiyle şirketler kendi rakiplerine karşı rekabet avantajı yaratmak adına maddi olmayan varlıklarının performanslarını arttırmaya yönelmişlerdir ancak şirketler bu konuda bazı problemler ile karşılaşmıştır çünkü finansal ölçüler maddi olmayan varlıkların performansının ölçülmesinde yeterli olmamaktadır (Geylan, 2007).

Kurumsal performansın değerlendirilmesi ve yatırım kararları verilebilmesi için kazanç hareketlerinin tahmini kullanılabilir. Makine öğrenmesinin algoritmalarından olan Destek Vektör Makineleri (SVM) algoritması ile şirketlerin finansal verileri kullanılarak gelecekteki kazançlarının ayrıntılı olarak tahmin edilmesi mümkün hale gelmektedir. Bu noktada, işletme bilgileri ve işletmenin finansal verilerinin elektronik

iletişimi maksadı ile oluşturulmuş bir raporlama dili olan ve raporlama hususunda işletme verilerinin hazırlanmasını, analiz edilmesini ve aktarılmasını sağlayan Genişletilebilir İşletme Raporlama Dili (XBRL, eXtensible Business Reporting Language)'nden alınan kapsamlı finansal verilere ihtiyaç duyulmaktadır (Baranes, 2019).

Bu bağlamda, XBRL'den alınan finansal verilerin kullanılması ile makine öğrenmesinin algoritmalarından olan Destek Vektör Makineleri (SVM) algoritmasının gelecekteki kazançlarının ayrıntılı olarak tahmin edilmesi mümkün hale gelmektedir. Kurumsal gelecek kazançlarının tahmin ediliyor olması yatırımcılar için hem yatırım kararları alma noktasında hem de kurumsal performansı değerlendirmek amacıyla kullanılmaktadır (Lev ve Gu, 2016).

Makine öğrenmesi algoritmalarından olan Destek Vektör Makineleri (SVM), esas olarak kredi riski değerlendirme işlevinde kullanılsa da finansal tahminler konusunda da uygulanmaktadır. Sinir ağları gibi diğer makine öğrenmesi teknikleri ile karşılaştırılabilir fakat o tekniklerden daha doğru sonuçlar ile kredi riski alanında daha etkili bir çözüm olarak görülmektedir (Danenas ve Garsva 2011).

Yapılan ölçümler ve örneklemelerde analistler SVM modelinin hisse başına karı daha iyi tahmin etmedeki yetersizliğinin nedeni olarak daha fazla bilgiye erişimi olduğu gerçeğine bağlamaktadır ancak model kümülatif getiriye tahmin etmede daha iyi performans göstermektedir. Sinir Ağları (Neural Networks) algoritması, deneysel risk minimizasyonu ilkesini uygulamaktadır ancak önemli bir dezavantaja sahiptir ki o da zayıflığa yol açan aşırı genelleme özelliğidir. Destek Vektör Makineleri, risk seviyesini azaltmakta ve daha yüksek bir doğruluk seviyesine yol açan üstün bir teknik olarak görülmektedir (Baranes, Palas 2019).

Sonuç olarak, finansal bilgileri kullanan makine öğrenmesine dayalı tahmin modelleri, geleneksel yöntemlere göre daha iyi performans göstermektedir. Önceki çalışmalardan daha doğru bir öngörü Destek Vektör Makineleri algoritması ve XBRL'den çıkarılan çok sayıda finansal bilginin kombinasyonu ile gündeme gelmektedir. Bu noktada, yatırımcılar bir yatırım kararı verirken bu araçtan faydalanabilmektedir. Makine öğrenmesi tekniklerini, özellikle de Destek Vektör Makinelerini, XBRL

verileri üzerinde uygulamak ve kazanç hareketini tahmin etmek için bir model oluşturmak çok sayıda verinin sürekli analizine izin vererek kullanılabilir hale geldikçe ve yatırım kararı almak daha kolay olmaktadır.

#### **2.2.4. HİSSE SENEDİ VE BORSA VERİLERİNİN ÖNGÖRÜSÜ**

Hisse senedi fiyat tahmini, hedef pazarlarda tutarlı ticaret kararlarının alınabilmesi için akıllı sistemlerin yaratılması konusunda geliştirilmiş bir yöntem bulunabilmesi amacıyla uzun zamandır birçok araştırmaya konu olmaktadır. Hisse senedi fiyatlarının öngörülebilmesi ve önceden tahmin edilebilmesi için farklı veri kaynakları ve makine öğrenmesi algoritmaları kullanılmaktadır. Borsa büyük miktarlarda veriyi her gün üretmektedir ve bu yüzden gelecekteki trendi öngörmesi için borsaların tüm güncel ve geçmiş bilgilerini değerlendirmek oldukça zor bir hale gelmektedir. Hisse senedi piyasaları dinamik, karmaşık bir yapıya ve oynaklığa sahiptir ve makine öğrenmesi sayesinde bu alandaki verilerin üzerinde tahmin yapılması kolaylaşmaktadır. Borsa işlemlerinde yapılacak olan yatırımların geleceği için alım satım yapılmadan önce analiz yapılması gerekmektedir. Hisse senetlerinin davranışlarını farklı yaklaşımlar ile inceleyen yatırımcılar alım satım stratejilerini de buna göre yapmaktadır (Site, 2020).

Makine öğrenmesi modellerinin farklı hisse senedi verileri ve hedef pazarlar üzerinde genellenmesi çözülmesi gereken problemlerden biridir. Bu noktada geleneksel makine öğrenmesi modelleri bazı karmaşık verileri modellemelerde yeterli olmamaktadır ve bu yüzden derin öğrenme tekniklerinin kullanılması finans alanında yaşanabilen problemlere daha doğru çözümler üretilmesini sağlamıştır. Derin öğrenme, veri setini kullanarak sonuçları öngören ve birden fazla katmandan oluşan bir makine öğrenmesi yöntemidir. Yapılan çalışmalarda tavsiye edilmiş olan derin öğrenme modelleri sayesinde hisse senedi veri setlerinden ortaya çıkarılan bilgilerle daha yüksek performans elde edildiği görülmüştür ve bu yaklaşım finansal manada borsa analiz teknikleri olan temel analiz ve teknik analizin karşımıdır. (Long ve diğ., 2018).

Büyük ölçüde kullanılan veri kümesine bağlı olan makine öğrenmesi modelinin performansı hisse senedi fiyat öngörüsü için en uygun modelin seçilmesini zor hale getirmektedir. Bu zorluğun üstesinden gelenebilmesi amacıyla çok sayıda farklı model ve karşılaştırmalı bir deney ve değerlendirme yapılmaktadır ve çok sayıda deney yapılabilmesi için

de çok sayıda hesaplama kaynağına ihtiyaç duyulmaktadır. Bu noktada, farklı veri kaynakları kullanılarak derin öğrenme modelleri ile hisse senedi tahmini ve trend analizi yapılabilmektedir (Site, 2020.)

Makine öğrenmesi yalnızca bulunan ülkenin ekonomisine bağlı olarak hisse senedi fiyatının üzerindeki etkisini değil aynı zamanda olumlu ya da olumsuz olan finansal haberlerin hisse senedi fiyatı üzerindeki etkisini de inceleyebilmektedir. Çünkü hisse senedi piyasası farklı birçok sektörü içermektedir ve farklı sektörleri içeren hisse senedi piyasası işletmelerin verilerinde bazı ilişkiler bulunmasına yol açarak yatırımcıların benzer sektörlerde bulunan işletmelere yatırım yapmasına neden olmaktadır. (Kanmaz, 2018).

Borsalar her zaman için düzenli bir şekilde değişim göstermemektedir yani her gün çok sayıda işlem olmakta ve dinamik, doğrusallığı bulunmayan bir sistem olduğu için öngörülebilirliği de kolay olmamaktadır. Önceki yıllarda matematiksel ve istatistiksel teknikler yardımıyla tahmin denemeleri yapılmış olup son zamanlarda özellikle de bilişim teknolojilerinin gelişmesi ve yapay zeka ve makine öğrenmesine dayalı algoritmaların sürece dahil olması ile önemli katkılar sağlanmıştır. Makine öğrenmesinin alt dalı olan derin öğrenme yöntemi ile hisse senetlerinin dinamikleri başarılı bir şekilde ortaya konulmakta ve öngörü çalışmalarında performans arttıracak kilit noktalar bulunmaktadır (Demirel, 2019).

### **2.2.5. KİŞİSEL FİNANSAL İŞLEM ENDEKSİ PUANLAMASI**

Kişisel finans ya da kişisel bütçe, bir kişinin gelir ve gideri, nakit akışı, koruma ve yatırım gibi faaliyetlerini planlaması ve yönetmesi sürecidir. Kişiler, doğru bir finansal planlama ve yönetim ile harcamalarını, tasarruflarını, gelecekte karşılaşılabilecek olan ve hedeflerin gerçekleşmesini etkileme gücüne sahip tehditlere yani finansal risklere karşı koruma ve yatırım gibi konuları daha fazla kontrol altına alabilmektedir. Finansal hedefler oluşturabilecek ve bu hedefler için bütçelerini planlayabilecekler ve bu sayede çeşitli aksiyonlar alınabilmesi de olanaklı hale gelmektedir. Sistem yaklaşımı ile bir araya getirilen kişisel finansman modellerinin bazı işlevsel yönleri ile bağlantılı olarak geliştirilen algoritmik bir model olan kişisel finans skor endeksi, sistemin doğruluğunu kullanıcı düzeyinde tahmin etmeyi amaçlamaktadır. Kişisel verilerin işlenmesine izin veren birçok uygulama olmasına karşın bu uygulamalardan çok küçük bir kısmı şirketlerin çözümleri tahmine dayalı bir şekilde ele almalarını



sağlamaktadır. Kişisel finans skor endeksi modeli, kullanıcılarına işlemlerin kategorilerine uygun, etkisiz ya da diğer sınıflandırmalar hakkında tahmin girdileri sağlamak noktasında etkili olmaktadır. Bu sayede potansiyel faktörler modele entegre edilmekte ve çözümde rol oynamaktadır. Çoğu uygulama, kullanıcılarının finansal hedefler belirlemesini ve belirlemiş oldukları kişisel hedeflerin takip edilebilmesini sağlamaktadır. Bütçe yönetimi uygulamaları, makine öğrenmesi algoritmaları ile kişilerin daha önceki harcamalarını ve ödemelerini analiz ederek onların harcamalarını planlamaya, fazla harcama konusunda uyarı yapmaya ve bütçelemeye yardımcı olan bilgileri sağlamaya yaramaktadır ve bu da en nihayetinde müşteriler ile bankalar arasında bir güven oluşturulmasını sağlamakta ve müşterilerin finansmanlarını daha etkin ve doğru bir şekilde organize etmelerine olanak tanımaktadır (Chakravarthy, Kumar, Ranganatham, Ramana, 2020).

Bankalar ve finansal hizmetler sektörünü daha erişilebilir kılan inovatif iş yapış modelleri ile teknolojiyi entegre eden FinTech şirketler, müşterilerinin yatırımlarının geri dönüşlerini daha da iyi hale getirmek için makine öğrenmesi algoritmalarını kullanmaktadır. Buna ek olarak, kişileri riskten kaçınma seviyelerine göre kategorize edip uzun vadeli finansal planlama sistemlerine referans olarak bir karşılaştırma yapabilmektedir. Bir finansal problemi karmaşık hale getiren finansal kararlar çok fazla belirsizliği içermektedir. Bu belirsizliklere örnek olarak kişinin iş yerinde göstermiş olduğu performans, riskten kaçınma derecesi, belirsizlikten kaçınma derecesi, özel hayata dair problemler ve sağlık koşulları verilebilmektedir. Bir portföy seçimi probleminde varlıklar ve borçlar girdi olarak alınmaktadır. Riskler, temel faktörler arasında çeşitlendirilmektedir. Amaç, özellikle piyasanın çöktüğü durumlarda yatırımcının sermayesi için kapsamlı bir koruma sağlamaktır. Ekonomik sistemler ve rejimlerin tanımlanması ise finansal planlama konusunda makine öğrenmesinin ikinci uygulamasıdır. Rejimler, çeşitli ortamlardaki piyasa koşulları olarak yorumlanabilmektedir ve buradaki amaç geleceğe yönelik varsayımlar yerine piyasa koşullarının ekonomik çöküşler esnasında daha dikkatli bir şekilde ele alınmasıdır. Çoğu borsa çökme dönemlerinde yüksek oranda düşüşler yaşadığı için yatırımcının sermayesinin korunması adına yatırım portföyüne hisse senedine ek olarak diğer varlıklar da eklenmiştir. Varlıklar her iki rejimde de iyi performans göstermekte ve bu sebeple kurumsal yatırımcılar için popüler

hale gelmiştir. Bu bağlamda, finansal planlama sistemlerinde riskleri minimize etmek için, tek rejimli stratejik bir ekonomi ortamı varsayılması yerine piyasayı daha doğru bir şekilde temsil eden gelecek zamana dair senaryolar geliştirilebilmektedir ve etkin bir risk yönetimi yapılarak yatırım performansı da iyileştirilmektedir (Mulvey, 2017).

Kişisel kredi notu yönetimi harcama, birikim, satın alma ve yatırım işlemlerinde kullanılmaktadır ve verilerin artmasıyla sonuçlar daha da iyileşmektedir. Müşterilere kişisel finans planlamaları için tavsiyelerde bulunulması makine öğrenmesi uygulamalarının kullanımı ile mümkün olmuştur. Önerilen kişisel finans skor endeksi ise gerekli parametrelere dayandırılarak kişisel finans çözümü sunmaktadır. Puanlama sistemi modeli için önerilen parametrelerden bazıları aşağıdaki tablodakiler olabilmektedir (Kumar, Chakravarthy ve diğ., 2021):

Aylık Gelir	Likit Varlıklar
Aylık Sabit Giderler	Kredi Risk Oranı
Kişisel Yükümlülükler	Kariyer Güvenliği
Ek Gelir Kaynakları	

Tabloda yer alan parametreler ve bu parametrelere benzer parametreler puanlama sistemi modeli için kullanılabilir. Varlıklar ve yükümlülükler dikkate alınarak bir değerlendirme sistemi geliştirilecektir. Model, sisteme kaydedilmiş olan her işlemi temel alarak kişinin endeks puanının otomatik olarak tahmin edilmesini gerçekleştirmektedir. Bu sayede, etkin bir şekilde risklerin minimize edilmesi sağlanmış olup, finansal planlamaların daha doğru bir şekilde organize edilmesi mümkün hale getirilmiştir (Kumar ve diğ., 2021).

## 2.2.6. TEDARİK ZİNCİRİ FİNANSMANINDA KOBİ'LERİN KREDİ RİSK TAHMİNİ

KOBİ'lerin (küçük ve orta ölçekli işletmeler) kredi riski analizi, gelecekte finansal manada bir zorluk yaşama ihtimallerinin tahmin edilmesi ile birlikte işletmelere kredi verecek olan finansal merkezin riskini minimize etmeyi amaçlamaktadır. Kredi riski analizi iki aşamadan oluşmaktadır. Bunlardan ilki müşterinin geçmişteki bilgilerinden yararlanılarak geleceğin tahmin edilmesini sağlayan müşteri başvuru skor analizi, ikincisi ise müşterinin yapmış olduğu kredi başvurusundan itibaren belirlenen bir süre boyunca müşterinin ödeme davranışlarının incelenmesi ve durumunun tahmin edilmesini esas alan müşterinin ödeme davranışının analizi olmaktadır (Kalaycı, 2018).

Yaşanan ekonomik gerileme gibi olumsuz finansal olayların KOBİ'lerin üzerindeki baskıyı arttırması sonucunda KOBİ'lerin artan kredi kullanım oranları, finansal merkezler tarafından müşteri riskinin daha doğru bir şekilde tahmin edilmesi gerekliliğini de beraberinde getirmiştir. Ticarete yaşanan dijitalleşme, pazarda rekabet edebilmek ve daha fazla pazar payı elde edebilmek için keskin bir rekabet avantajı yaratmaya yönlendiren faktörlerden biridir. Günümüzde finansal merkezler tarafından müşteri riskinin daha doğru tahmin edilebilmesi için makine öğrenmesi modelleri kullanılmaktadır. Finansman sorunları KOBİ'lerin işletme faaliyetleri esnasında en çok karşılaştıkları sorunlardan biri olmaktadır. Nakit akışlarını iyi planlayamayan KOBİ'ler bu konu ile ilgili olarak sorun yaşamaktadır ve genelde nakit akışlarını iyi planlayamayan şirketlerin battığı görülmektedir. Öte yandan KOBİ, ülkelerin ekonomik kalkınması için önemli bir güç olmaktadır (Lawal ve Akingbade, 2018). KOBİ'lerin faaliyetleri esnasında finansman problemlerinin çözülme aracı olarak tedarik zinciri finansmanının finans kuruluşları tarafından kullanılması ile küçük ve orta ölçekli işletmelerin tedarik zinciri finansmanındaki kredi riskinin öngörülmesi finansman kararlarının verilmesinde en önemli konulardan biri haline gelmiştir ve bu noktada makine öğrenmesi modelleri birçok araştırmacı tarafından en iyi araç olarak savunulmaya başlanmıştır ancak geleneksel kredi riski tahmin modelleri bu tahmin için gereken nitelikleri karşılamamaktadır. Bilhassa finansal sıkıntı ve operasyonel anlamda çok fazla risk ve belirsizlikler ile dolu bir ülkede rekabet ortamı ile karşı karşıya kalan KOBİ'lerin daha çok problem ile karşılaşma ihtimali artmaktadır. Çok fazla risk ve belirsizliğin olduğu ülkelerde KOBİ'leri finanse etmek reddedilebilir çünkü KOBİ'lerin düşük kredi puanına sahip olduğu düşünülmektedir ve düşük kredi puanı finansal araçları korkutmaktadır. Bu probleme yönelik bir çözüm olarak da bazı ülkeler finansal araçları KOBİ'lere kredi vermeye teşvik etmektedir ve KOBİ'lere kredi garantisi vermektedir. Bu sayede, finansal araçlardan minimum maliyette finansman elde edilmektedir (Zhu ve diğ., 2019).

Tedarik zinciri finansmanı organizasyonlar arası düzeyde finansal kaynakların akışını planlayarak, onları yönlendirerek ve kontrol ederek tedarik zinciri üzerindeki aktörlere değer yaratmak için bir finansman aracı olarak tanımlanmaktadır. Özellikle görece daha zayıf tedarik zincirleri üzerindeki aktörler için düşük borç maliyeti, yeni kredi fırsatları, düşük işletme sermayesi sağlamaktadır. Son zamanlarda KOBİ'lerin finansman gereksinimlerini karşılayabildikleri için de oldukça önemli bir araç haline gelmiştir (Ali, Gongbing, 2018).

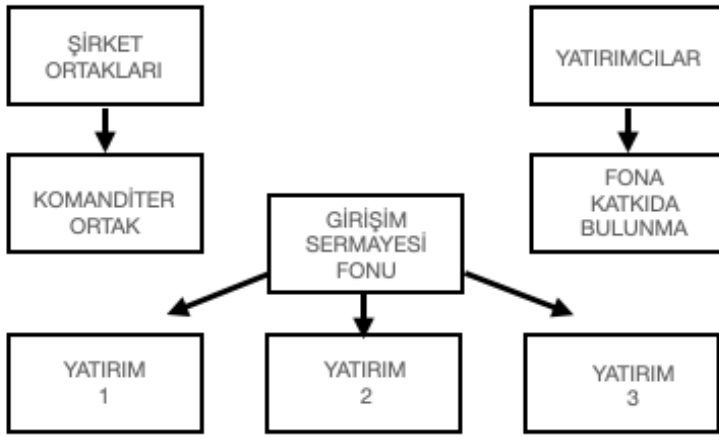
Sonuç olarak, KOBİ'lerin rakiplerine karşı rekabet gücü ve avantajı elde etmek ve küreselleşmenin zorluklarıyla baş etmek amacıyla dinamik bir tedarik zinciri üretebilmek için kolay kredi elde etmek adına finansman arıyor olmaları pazardaki rekabetin artmış olmasından, sermaye eksikliklerinden ve küreselleşmeden kaynaklı olmaktadır. Dinamik bir tedarik zinciri üretmeye odaklanan KOBİ'ler finansman performansı ve tedarik zincirlerindeki güçlerini artırma amacı ile operasyonlarını düzenlemekte, bilgi akışlarının ve malzeme akışlarının kontrolünü sağlamalarının yanı sıra odak noktaları nakit akışlarını tasarlamak ve maksimize etmek olarak belirleyerek diğer şirketlere yönelik rekabet avantajı kazanmaktadır. Tedarik zinciri finansmanı (SCF) bu noktada işletme sermayesini arttırmak için para akışlarını denetleyen, planlama yapan ve kontrol eden bir finansman ürünüdür ve işletmelerin nakit akışını optimize etmeye hedefleyerek ve onların finansal kuruluşlardan kredi alabilmesini sağlayarak belirlemiş oldukları hedeflere zamanında ulaşmalarını desteklemektedir. En nihayetinde KOBİ'ler ülkelerin uluslararası verimliliğini artırma noktasında hem bilimsel hem teknoloji destekli ilerlemeler ile ekonomik altyapının geliştirilmesinde fayda sağlamaktadır. (Ali ve diğ., 2020).

### **2.2.7. RİSK SERMAYESİ KARARI**

Risk sermayesi ya da girişim sermayesi, dinamik, yaratıcı ve yenilikçi olan bir girişimcinin ya da firmanın start-up'ı için finansmana ihtiyaç duyduğu takdirde kendisine finansal kaynak araması ve yeni start-up'ları destekleyen ve oluşabilecek riskleri almaya hazır olan uzun vadeli yatırımcılar ile bir araya gelmesidir. Yatırım yapan kişi ya da firmalar, şirket başarılı olduğu takdirde uzun vadede önemli bir kazanç elde edecektir ancak risk sermayesi bir kredi olarak düşünülmemelidir, kredinin geri ödenmesi gerekirken risk sermayesinin geri ödenmesi gerekmemektedir,

risk sermayesi yatırımcılarının kazancı yatırım yaptıkları şirketlerden özsermaye yatırımları üzerinden geri ödeme olarak olmaktadır. Yatırımcılar için bu durum yüksek tehlike teşkil edebilmektedir. Yatırımcılar arasında ticari bankalar, yatırım bankaları, sigorta şirketleri, vakıflar, yatırım fonları, üniversiteler, özel sermaye kuruluşları ve nakit zengini şirketler olabilmektedir. Risk sermayesi yatırımcılığı bir tür melek yatırımcılığa da benzemektedir. Bu bağlamda risk sermayesi, yüksek miktarda gelir sağlayabilmesinin yanı sıra risk almak söz konusudur ve bu nedenle risk yönetimi etkin bir araştırma ve bilgi birikimi ile desteklenmelidir.

Makine öğrenmesine dayalı risk sermayesi kararı kişinin karar verme sürecinde destek sağlamaktadır. Risk sermayesi yatırımı yüksek getirili bir yatırımı oluştursa da beraberinde getirdiği risk de yüksek olmaktadır. Risk sermayesi kararı için makine öğrenmesi modelleri risk sermayedarları için riski minimize etmek adına önem taşımaktadır.



**Şekil 2:** Makine öğrenmesine dayalı girişim sermayesi diyagramı.

**Kaynak:** <https://ars.els-cdn.com/content/image> **Son Erişim Tarihi:** 04.07.2021

Yukarıdaki diyagram makine öğrenmesine dayalı girişim sermayesini göstermektedir. Aday olan şirketlerin büyüme stratejisinin nasıl gerçekleştirileceği ve nasıl yönetileceği risk sermayesi kararı için yapılan değerlendirme sürecinde önemli bir faktör olmaktadır. Makine öğrenmesi de rekabet sürecinde satış gücüne, portföy şirketi ile olan ilişkiye ve tanımlama girişimine bağlı olarak işlemektedir. Şirketin satış ve kar planlaması, yatırım maliyeti de değerlendirme için ilk ölçütler olmaktadır.

Makine öğrenmesi, yatırımcılara potansiyel start-upları değerlendirerek, tutarsız verileri bularak onlar hakkında satış ve kar planlamalarına ve yatırım maliyetlerine dair daha doğru bilgiler sağlayarak yatırımcıların öğrenme sürecini hızlandırırken potansiyel girişimler ile birleşmeleri ve satın almaları belirleme noktasında start-up şirketlere ve onların büyümelerine de destek olabilmektedir. Bunu, verilere dayalı bir öğrenme yöntemi ile şirketlerin gelecekteki başarısını tahmin etmeye çalışarak yapmaktadır ve en nihayetinde en iyi yatırımı seçmektedir. Buna ek olarak, ortak yatırımcıları da ele alarak bazı güçlükleri de tanımlayabilmektedir. Yatırımcılar ise makine öğrenmesinin sağlamış olduğu bilgilerin ardından potansiyel olasıları değerlendirerek nihai kararı vermektedir ve bu sayede makine öğrenmesi yatırımcıların başarı oranını artırma noktasında destek sağlamış olmaktadır (Yang, 2020).

### **2.2.8. KRİPTO PARA BİRİMİ ENDEKSİNİN TAHMİN EDİLMESİ**


Günümüzde, kripto para birimi dünya çapında en fazla işlem gören finansal araçlardan biri haline gelmiştir. Kripto para birimlerinin yüksek oynaklığa sahip olması, agresif dalgalanmalar yaşaması yani bir gecede çok hızlı bir şekilde değer kaybetmesi ya da kazanabilmesi ile fiyatların tahmin edilmesinin zorlaşması nedeniyle yatırımcılar birtakım güçlükler ile karşı karşıya kalmaktadır ve bu noktada makine öğrenmesi modelleri ve algoritmaları yatırımcılar için fiyatların tahmin edilebilmesini ve bu sayede kripto para piyasasındaki riski minimize etmeyi sağladığı için kullanılabilir. Fakat bu tahminin yapılması tek bir algoritma ya da model kullanılarak değil birçok farklı algoritma ile incelendiği takdirde daha doğru sonuç vermektedir. Kripto para birimi endeksinin tahmin edilmesi için önerilen makine öğrenmesi modellerinden bazıları Destek Vektör Makineleri ve Sinir Ağları olmaktadır (Chowdhury ve diğ., 2020).

Kripto para birimlerinin fiyat ve işlem sayısındaki istikrarsız ve ani dalgalanmalarının öngörülebilmesi ve tahmini için önerilen bir yöntem olan kullanıcı yorumları analizi, önemli faktörleri belirleyerek kripto para birimleri ile yorumlar arasında bir ilişki kurmaktır. Kullanıcı yorumları için kişilerin görüşlerini paylaştığı çevrimiçi topluluklardan yararlanılmaktadır. Kripto para birimleri de çevrimiçi olarak alınıp satıldığı için birçok kullanıcı çevrimiçi topluluklar tarafından verilmiş olan bilgilere dayanarak karar vermektedir. Kullanıcı yorumları ile kripto para birimlerinin fiyat ve işlem sayısındaki dalgalanmalarla olan ilişkisi

belirlendikten sonra dalgalanmaların tahmin edilmesi için seçilmiş olan verilere dayanan bir makine öğrenmesi modeli kullanarak tahmin yapılmaktadır (Kim ve diğ., 2016).

Çevrimiçi platformlardaki kullanıcı yorumlarının desteği ile kripto para birimlerinin işlem sayısı ve fiyatının tahmin edilebiliyor olması makine öğrenmesi modelleri ve algoritmaları sayesinde mümkün olmaktadır. Üzerinde durulması gereken konu, yapılan tahminin doğruluğunu arttırabilmek amacıyla iyileştirmeler yapılması gerektiğidir. Bir dizi iyileştirme yapıldığı takdirde kripto para birimlerinin anlaşılabilirliği ve kullanılabilirliği artacaktır (Kim ve diğ., 2016)

Yüksek volatilité ortamında kripto para birimlerinden ilki olan Bitcoin'in döviz kurunun tahmin edilmesi için yapılan çalışmalardan biri de Autoregressive Integrated Moving Average (ARIMA) kullanılarak tahmin yapmaktır. ARIMA modeli, verileri daha iyi anlayarak, zaman serilerini kullanarak ve istatistiksel analizler yaparak gelecekteki eğilimleri tahmin etmektedir (Bakar ve Rosbi, 2017).



**Şekil 3:** ARIMA modeli kullanılarak kripto para endeksi tahmin süreci

**Kaynak:** Nashirah Abu Bakar, Sofian Rosbi, ‘‘Autoregressive Integrated Moving Average (ARIMA) Model for Forecasting Cryptocurrency Exchange Rate in High Volatility Environment: A New Insight of Bitcoin Transaction’’, s. 132, 2017.

Tahmin süreci, veri seçimi ile başlamakta ve daha sonrasında ARIMA yöntemi kullanılarak veri modelinin tanımlanmasıyla devam etmektedir ve ardından tahmin ve hata denetimi aşamasına geçilmektedir. Yatırımcıların daha yüksek bir kar elde etmelerine ve yatırım kararlarındaki kayıpların azaltılmasına yardımcı olması açısından Bitcoin'in gelecekteki döviz kurunun tahmin edilmesinde ARIMA modeli de etkili olmaktadır (Bakar, Rosbi, s.132, 2017).

Makine öğrenmesi teknikleri ve modelleri, kripto para birimleri işlemlerinin fiyatlarındaki istikrarsız dalgalanmaları ve agresif değişimlere yönelik yaptığı kripto para endeksine yönelik yaptığı tahminler ile ön plana çıkmaktadır. Makine, bir kripto para biriminin gelecekteki kapanış fiyatının tahmin edilebilmesi için veri kümesinden öğrenecek şekilde eğitilmelidir. Farklı modellerin desteği ile veri setine dayalı olarak tahmin yapılmaktadır.

### **2.2.9. FİNANSAL DOLANDIRICILIK VE FİRMALARDAKİ USULSÜZLÜKLERİN TESPİTİ**

Bir ekonominin kritik bileşenlerinden olan hisse senedi ve tahvil piyasalarının verimliliği, likiditesi ve esnekliği yatırımcıların, borç veren kurumların, düzenleyicilerin finansal performansını değerlendirme yeteneğine bağlı olmaktadır. Hazırlanan finansal tablolar, sermaye piyasalarının etkin tutulmasını desteklemektedir. Şirkete ve finansal durumuna ilişkin anlamlı açıklamalar sağlayarak bilgilendirmeler yapmaktadır ve genel kabul görmüş muhasebe ilkelerine dayanmaktadır. Ancak, finansal tablolar kimi zaman kasıtlı bir şekilde yanlış ifadeler verecek biçimde düzenlenebilmektedir (Chimonaki, Papadakis, Vergos, Shahgholian, 2019).

İçinde bulunduğumuz ve Sanayi Devrimi'nin dördüncü aşaması olan Endüstri 4.0, şirketlerde usulsüzlük yapılmasını bir taraftan daha kolay bir hale getirirken diğer bir taraftan da şirketlerdeki usulsüzlüklerin tespiti noktasında kullanışlı yeni araçları ortaya koymaktadır. Muhasebe konularında yapılan usulsüzlükler dünya çapında bir problem teşkil etmektedir çünkü bu usulsüzlükler zamanında tespit edilip önlenmezse dolandırıcılık yapan şirketlerin paydaşlarına önemli zararlar verirken dolaylı olarak denetim firmalarının performanslarının eleştirilerek aslında dolandırıcılık yapılmamış olan şirketlerin paydaşlarını da olumsuz manada etkilemektedir. Finansal dolandırıcılık, bir taraftan yatırımcıların



ciddi miktarda kaybetmesine hatta iflasa neden olabilecek önemli mali sorunlara neden olurken bir taraftan da kurumsal yönetimde bir güven krizi ortaya çıkarmaktadır. Bu finansal usulsüzlerin tespit edilmesi ve ortaya çıkarılması, denetçiler tarafından değerlendirilmesi çok zordur ve tespit edilse dahi genelde geç kalınmış olduğundan ciddi zararlar çoktan verilmiş olmaktadır fakat bu noktada makine öğrenmesi algoritmaları ön plana çıkmaktadır. Makine öğrenmesi algoritmalarının finansal tablo sahtekarlığı, kredi kartı dolandırıcılığı, menkul kıymetler ve emtia dolandırıcılığı ve sigorta dolandırıcılığı gibi finansal usulsüzlüklerin tespit edilmesini sağlaması hem yatırımcılar hem denetçiler başta olmak üzere herkes için ciddi manada önemli bir gelişmedir. Makine öğrenmesi yöntemleri ile bu tür usulsüzlerin tespitinin doğru olması gerekliliğinin yanında insanlar tarafından yorumlanabilirliğinin kolay olması da pratikte benimsenebilmesi açısından gerekmektedir (Hajek, Henriques, 2016).

Son yıllarda artan muhasebe dolandırıcılığı kurumsal finansal raporlama sürecine daha çok odaklanılmayı beraberinde getirmiştir. Finansal tablo usulsüzlüğü, finansal bilgilerin genel kabul görmüş muhasebe ilkelerine uygun olarak raporlanmamasından kaynaklanan eksiklikler ve yanlış beyanlardır. Finansal raporlamanın güvenilirliğine olan inancı korumak için kanunlar ve yönetmelikler tarafından firmaların finansal olarak yanıltıcı, eksik ve doğru olmayan beyanlarda bulunmasını yasaklamıştır. Ayrıca muhasebe denetimleri firmaların finansal tablolarının herhangi bir hata içermediğine dair makul bir güvence sağlamaktadır. Bu usulsüzlük, yatırımcılar, denetim firmaları ve diğer sermaye piyasası paydaşları tarafından endişe ile karşılanmaktadır. Bu bağlamda, paydaşların doğru karar vermesine katkıda bulunmak amacı ile makine öğrenmesi teknikleri kullanılarak dolandırıcılık riskini daha erken belirleyebilen ve eğilimler ile kalıpları daha kolay ortaya çıkarabilen dolandırıcılık tespit sistemleri geliştirilmiştir ve bu sayede finansal tabloların hileli bir şekilde sunulmasının engellenmesi amaçlanmıştır. Bu bağlamda artık firmalar, dolandırıcılık ya da hırsızlığı önlemekten potansiyel olarak sorumlu tutulabilmektedir. Çünkü, şirketler finansal suçlara karşı daha etkin politikalar, prosedürler ve kontroller uygulamaları gerektiği konusunda bilgilendirilmiş olup bu tür usulsüzlüklerin erken tespiti de teknoloji destekli makine öğrenmesi algoritmaları tarafından mümkün kılındığı için önlem alma konusunda güçlü ve yeterli kontrollere sahip olmalıdır. (Hipgrave, 2013).

Halka açık firmalardaki usulsüzlüklerin tespit edilebilmesi için kullanılan en bilindik makine öğrenmesi modelleri M-Skor Modeli ve F-Skor Modelidir. Hem M-Skor modelinde hem de F-Skor modelinde birkaç finansal oranın hesaplanması gerekmektedir ve belli bir eşiği aşan bir değerin olması finansal tabloların manipüle edilmiş olabileceği riskinin var olduğu üzerine yorumlanmaktadır. Hangi finansal tablonun manipüle edilmiş olabileceği bu modeller tarafından belirlenebilmektedir ve buna göre bir sonraki yıllık finansal tablonun manipüle edileceğinin tahmininin yapılmasında da kullanılmaktadır.

Aynı veriler kullanılarak yapılan bir araştırma makine öğrenmesi algoritmalarından biri olan Neural Networks (Sinir Ağları) algoritmasının Linear Regression (Doğrusal Regresyon) veya Logistics Regression (Lojistik Regresyon) algoritmalarından daha iyi performans gösterdiğini ortaya koymaktadır. Modellerin çoğu yalnızca yıllık verileri kullanmaktadır çünkü genel manada yıllık verilerin manipülasyonu hissedarlar için önemli olmaktadır. (Wyrobek, 2020).

Akıllı telefonların artan kullanımı ve e-ticaret modellerinin yaygınlaşması ile birlikte dijital ortamlarda gerçekleştirilen ödemeler için fiziksel bir ödeme aracı gerekmediği için kimlik ya da kredi kartı çalınması ile gerçekleştirilen finansal dolandırıcılık konusu çok sık görülmekte olan ve hızla büyüyen bir problem haline gelmektedir. Bu noktada, finansal dolandırıcılığın dijital kanallarda da fiziki ortamlarda olduğu gibi tespit edilmesi ve önlenmesi gerekmektedir. Finansal dolandırıcılığın tespiti makine öğrenmesi modelleri ile büyük miktarda verinin işlenmesi ile mümkün olmaktadır (Choi, Lee 2018).

Bir banka müşterisinin kredi çekerken, kredinin onaylanmasından önce kararlaştırılmış olan yasal yükümlülüklerini ve koşullarını uygulayamadığında meydana gelen temerrüde düşmüş krediler konusuna ilişkin olarak dolandırıcılıkların tespit edilebilmesi ve önüne geçilebilmesi için teknolojinin kullanılması yaygınlaşmaktadır. Çünkü, kredi temerrütleri konusu bankaların kapanmasından ülkelerin ekonomik durgunluk yaşamasına kadar varabilen ciddi sonuçlar doğurabilmektedir. Kredi başvuruları konusunda temerrüde düşme olasılığının yüksek olduğu ve krediyi çeken kişi tarafından geri ödenmemesi muhtemel olan ve normalde onaylanmaması gereken kredilerin bilinçli olarak verilmesi

ve bu sebeple dolandırıcılık olasılığının tahmin edilmesi için de makine öğrenmesine dayalı denetimli bir öğrenme modeli kullanılmaktadır. Aslında geleneksel dolandırıcılık tespiti yöntemleri var olsa da bazı kısıtları olduğundan çok fazla zaman almaktadır. Riskli kredilerin ve temerrüde yol açacak onayların olası bir usulsüzlüğünü veri madenciliği yolu ile verilerin arkasında neler olduğuna dair modeller oluşturarak gizli kalıpların ve özelliklerin ortaya çıkarılması ile makine öğrenmesi, geleneksel yöntemlere göre daha hızlı bir şekilde keşfedebilmektedir (Eweoya, Adebisi, Azeta, Amosu 2019).

### **2.2.10. FİNANSAL KRİZİN ERKEN TAHMİNİ**

Finansal kriz, herhangi bir mal, hizmet, üretim veya döviz piyasasındaki fiyat veya miktarlarda, ani ve beklenmedik bir biçimde ortaya çıkan, kabul edilebilir bir sınırın üstünde meydana gelen ve ülke ekonomisinde önemli problemler ortaya çıkaran şiddetli dalgalanmalar olarak tanımlanabilmektedir (Kibritçioğlu, 2001). Makine öğrenmesi modelleri, finansal kriz dönemlerinin önceden belirlenmesinde, finansal başarısızlıkların tahmininde, enflasyon tahmininde ve finansal kriz ya da finansal bulaşma gibi konularda erken uyarı sistemlerinin geliştirilmesinde oldukça yaygın bir kullanım alanına sahip olmaktadır (Tosunoğlu ve Benli, 2012: 541). Buna ek olarak finansal bağlantılar içindeki finansal bulaşma riskini tahmin etmek için de kullanılmaktadır. Bunun için, votaliteyi tespit ederek tahmin edebilen, bulaşma kanallarını belirleyebilen erken bir uyarı sistemi geliştirilmesi mümkün olmaktadır. Bu zamana kadar birçok çalışma finansal zaman serilerini tahminlenmesi problemlerinde başarı gösteren Destek Vektör Makinelerine dayalı Garch modelini kullanarak finansal piyasalar arasındaki votalite ve korelasyon dinamikleri incelenmiştir. Destek Vektör Makineleri bu zamana kadar yapılan çalışmalarda en doğru tahmini yapan sınıflandırıcı olarak nitelendirilmektedir. Volatilitenin modellenmesi ve tahminlenmesi finansal riskin ve krizin yönetilmesinde önemli bir rol oynamaktadır. Modellemede finansal ekonometri konusunda geliştirilen birçok model mevcut olmasına karşın en çok kullanılan model Garch modeli olmaktadır ve klasik makine öğrenmesi algoritmalarına karşı daha gerçekçi olmaktadır (Gürsoy ve Balaban 2014).

## 2.2.11. MUHASEBEDE DENETİM ARACI OLARAK MAKİNE ÖĞRENMESİ

Makine öğrenmesi algoritmaları ve teknikleri muhasebe ve denetim alanlarında oldukça kritik bir öneme sahiptir ve bu alanlarda yaygın bir kullanıma sahip olduğu görülmektedir. Belirsizliğin ve kararsızlığın hakim olduğu şartlarda başarılı sonuçlar veren muhasebe alanında denetim, finansal analiz, vergilendirme, yatırım kararları gibi faaliyetlerde oldukça geniş bir kullanım potansiyeline sahiptir (Erdoğan, 2005).

Makine öğrenmesi algoritmalarının kullanılması muhasebe denetiminin her sürecini etkilemektedir. Makine öğrenmesi algoritmaları sayesinde şirket içerisinde gerçekleşen yanlışlıklar ve hilelerden doğan hataların belirlenmesi daha kolay olmaktadır. Denetim sürecinin son aşaması olan bulguların raporlanması sürecinde finansal tabloların doğruluğuna dair makul bir güvence verilmiş olmaktadır (Karaduman, 2017).

Çok büyük miktarda verinin analiz edilmesini gerektiğinden normal denetim prosedürü zaman alıcı olmaktadır. Bu bağlamda bir denetim görevi yürütülürken denetim sürecinin her aşamasında finansal dolandırıcılıkların tespit edilmesi için daha yüksek teknolojiye duyarlı olan makine öğrenmesi algoritmaları, hataları ve hileleri tespit etme noktasında fayda sağlayarak sürecin olabilecek en hızlı şekilde ilerlemesini desteklerken hata oranını da minimize etmektedir. Matematiksel bir model olan Beneish modeli finansal oranları ve şirketin finansal tablolarından elde edilen bilgileri kullanarak bir denetçinin şirketi manipülatör ya da manipülatör olmayan olarak sınıflandırmasını mümkün kılmaktadır. Diğer modellerin aksine, makine öğrenmesi yaklaşımı, veri analitiğine ilişkin daha fazla içgörü elde etmek için veri madenciliği gibi karmaşık teknikleri içerir ve veri madenciliği yaparak çok sayıda veriden faydalı bilgiler çıkarabildiği için denetçilerin yalnızca en ideal ve uygun olan seçeneği kullanarak daha iyi performans göstermelerini sağlamaktadır (Dbouk ve Zaarour 2017).

Şirketlerin finansal tablolarının doğruluğuna dair makul bir güvence sağlamayı amaçlayan bağımsız denetim şirketleri, son zamanlarda artarak daha sık hale gelen hileli finansal tabloların tespiti konusunda sorumludur (Cullinan, Sutton, 2002). Denetim şirketleri, mevcuttaki denetim yöntemlerindeki eksikliklerin bilincindedir. 1980 yılının ortalarından itibaren modern denetim veya risk temelli denetim olarak adlandırılan

hata içerme olasılığı daha yüksek olan alanlara daha çok odaklanılmayı ve daha fazla kaynaktan elde edilmiş olan kanıtları incelemeyi öne süren denetim modeli benimsenmiştir. Teknolojik ilerleme ve şirketlerin sürekli olarak teknolojiye entegre olması, muhasebe dolandırıcılıklarının tespitinde de daha yüksek bir teknolojiye duyarlı bir prosedür gerektirmektedir. Çünkü, analiz edilmesi gereken veri büyük miktarda olduğundan normal denetim prosedürleri ile bu durum çok zaman almaktadır ve günümüzde denetçilere ayrıca zorluk çıkarmaktadır (Sharma, Panigrahi 2012). Bu nedenle varsayılan denetim prosedürlerini tamamlayacak ve güçlendirecek nitelikte olan etkin yöntemlerin ve prosedürlerin geliştirilmesi zorunlu hale gelmiş ve bu sayede kurumsal yönetim konularında dolandırıcılıkları tespit etmek, raporlamak ve değerlendirmeyi sağlamak da mümkün hale gelmiştir (Dbouk, Zaarour 2017). Ayrıca finansal tabloların daha şeffaf, tutarlı ve daha fazla bilgi içermesi için artan bir talep mevcuttur (Spathis, Doumpos, Zopounidis, 2003). Bu talep karşısında denetçilerin her denetim sürecinde hile ve usulsüzlük riskini değerlendirmeleri gerekmekte ve bu değerlendirme yapılırken hem iç kontrol sisteminin hem de yönetimin kontrollere yönelik tutumunun dikkate alınması gerekmektedir. Bu bağlamda, yönetimin özellikleri ve etkisi, sektör koşulları, operasyonel nitelikler ve finansal manada istikrar konuları finansal raporlamayla ilgili olan risk faktörlerini teşkil etmektedir. Yönetimden kaynaklanan usulsüzlükleri tespit etmek yöneticiler tarafından denetçilerin kasıtlı olarak aldatılması (Fanning, Cogger, 1998), bazı denetçilerin bunu tespit edebilmek için deneyimsiz oluşu ve bilgi eksiklikleri nedeniyle geleneksel denetim prosedürleri güç olmaktadır (Porter, Cameron 1987). Bu nedenle veri analitiğine dair daha fazla tahmin elde etmek için büyük veri setlerinden faydalı bilgiler çıkaran veri madenciliği gibi teknikleri içeren makine öğrenmesi modellerinin doğru ve etkin kullanımı sonucunda manipülatör olan veya olmayan şirketlerin sınıflandırılması için kullanılacak finansal tablolardaki olası şüpheleri ortaya çıkarılabilmektedir (Hogan ve diğ. 2008).

Farklı farklı birçok finansal dolandırıcılık türleri bulunmaktadır. Başvuru, derecelendirme, faturalandırma gibi sigorta sürecinin birçok evresinde acenteler, komisyoncular, sigorta şirketi çalışanları tarafından gerçekleştirilerek meydana gelebilen sigorta dolandırıcılığı; piyasa manipülasyonu, yüksek getirili yatırım dolandırıcılığı, döviz dolandırıcılığı gibi menkul kıymetler ve emtia dolandırıcılığı; şirketlerin finansal durumlarını yansıtan temel belgeleri olan finansal tablo dolandırıcılığı; bir krediyi finanse etmek için borç veren bankaları ya da kurumları etkilemek adına bir mülkün ipotek belgelerinin manipüle edilmesini ifade eden mortgage dolandırıcılığı ve kredi kartı dolandırıcılığını da içeren tüm dolandırıcılık biçimlerinin incelenebilmesini zorlaştıran en büyük faktör veri kıtlığı olmaktadır (Lopez-Rojas ve Axelsson, 2016). Bu nedenle araştırmacılar benzerlikleri ön plana çıkararak gerçek bir veri setinden sonra yapay veri setleri oluşturularak yaklaşımların doğruluk oranını arttırmaya çalışmakta ve daha kolay bir şekilde karşılaştırmalar yapılmasını sağlamaktadır. Oluşturulan yapay verileri kullanan makine öğrenmesi modelleri, bankacılık, perakende sektörü, çevrimiçi ödemeler gibi çeşitli alanlarda öngörü edinilmesine katkıda bulunmuştur (Gaber ve diğ. 2013).

Yapılan son çalışmalar ile, yönetimde usulsüzlükler yapan ve yapmayan şirketleri analiz ederek usulsüzlüklerin varlığını tahmin edecek makine öğrenmesi modelleri oluşturulmaya çalışılmıştır. Yapılan analiz, usulsüzlüklerin yapılmadığı şirketlerde, dolandırıcılık yapan şirketlere göre önemli ölçüde yüksek dış üye yüzdesine sahip yönetim kurulu bulunduğunu göstermiştir (Beasley, 1996). Hansen ve diğerleri (1996), veriye dayalı olarak yönetim sahtekarlığını tahmin etmede uluslararası muhasebe şirketi tarafından geliştirilmiş olan bir modeli kullanmaktadır. Geliştirilmiş olan makine öğrenmesi algoritmalarını kullanan denetçiler yönetimde hile riskini belirlemede daha doğru kararlar vermekte ve daha tutarlı kararlar almaktadır. Hileli finansal tabloların belirlenmesi bir sınıflandırma problemi olarak kabul edilmektedir. Sınıflandırma konusunda Karar Ağaçları, Sinir Ağları ve Bayesian algoritmaları öne çıkmaktadır. Algoritmalar veri madenciliği, istatistik ve yapay zeka alanlarından türetilmiştir ve bu teknikler denetçilerin yönetim usulsüzlüklerini tespit etme görevini yerine getirmesini kolaylaştırmaktadır (Kirkos ve diğ. 2007). Bir işlemin gerçek zamanlı olarak hileli olduğunun tespit edilmesi,

usulsüzlüklerin önlenmesi açısından bir önlem olarak kullanılabilir (Vaughan, 2020). Geleneksel bağımsız denetim istatistiksel olarak mutabakat, stok sayımı konularını el ile yapılırken; makine öğrenmesi modellerine dayalı denetimde mutabakat otonom hale getirilmiştir. Buna ek olarak geleneksel denetim süreçleri dönemsel olurken, makine öğrenmesi modellerinin desteği ile süreklilik sağlanmaktadır. Bu sayede makine öğrenmesi modelleri geleneksel denetim süreçlerine dahil edilerek süreçleri sadece hızlandırıp doğruluklarını arttırmakla kalmamakla birlikte aynı zamanda finansal bilgilerin güvenilirliğini de artırma noktasında etkili olmaktadır (Kuenkaikaw, Vasarhelyi 2013). Ayrıca, geleneksel denetim prosedürlerinde denetçiler maaş bordrosu veya kazançlar gibi pek çok hesabı manuel olarak doğrulamak zorundayken makine öğrenmesi ile genel denetim hedeflerine ulaşmak amacıyla mali tablolardaki yanlış beyanların tespiti asgari bir çaba ve zaman ile gerçekleşmektedir (Sayana, 2003). Geleneksel denetim prosedürleri dezavantajlı görünse de hala ihtiyaç duyulmaktadır ve matematiksel ve makine öğrenmesi modellerinin uygulanması ile geleneksel yöntemlerin modernleştirilmesi amaçlanmaktadır (Dbouk, Zaarour, 2017). Sonuç olarak, riske dayalı denetim önemli ölçüde daha geçerli ve güvenilir sonuçlar ortaya koymakta ve yüksek kaliteli raporlar üretmektedir. Bu nedenle denetçilerin teknoloji ve kullanımı konusunda eğitimlere katılmaları önem arz etmektedir, çünkü bilgi sahibi olmaları yanlışlıkları tespit etmek ve hatalı görüşleri önlemek adına makine öğrenmesi modellerini kullanmalarını kolaylaştıracaktır.

## SONUÇ

Bu çalışmada makine öğrenmesinin mevcut veriler ile geleceğe ilişkin tahminlerde bulunmak için modeller kullanarak finansman ve muhasebe alanlarındaki uygulamalarda büyük bir dönüşüm ortaya çıkardığı üzerinde durulmuştur. Özellikle son yıllarda makine öğrenmesi algoritmaları üzerinde yapılan çalışmalar önemli düzeyde artmıştır ve iş süreçlerinin çok önemli bir parçası haline gelerek insanların iş yapma biçimlerini değiştirmiştir. Makine öğrenmesi araçları birçok dezavantaja da sahip olmasına karşın kullanımının işletmelerde daha hızlı veri analizini mümkün kılması ile risklerin daha önceden tahmin edilmesi sağlanmış ve bu kapsamda verimlilik maksimize edilirken aynı zamanda hata oranı da minimize edilmiştir.

Makine öğrenmesi araçlarının kullanılması ile şirketlere sağlanmış olan birçok faydanın yanı sıra rekabet avantajı yaratma noktasında da avantaj sağlamıştır. Makine öğrenmesi algoritmalarının finansman ve muhasebe süreçlerine dahil edilmesi ile maliyet minimizasyonu, zaman tasarrufu, arttırılmış güvenlik, müşteri deneyiminin gittikçe iyileştirilmesi gibi birçok avantaj gündeme gelmiştir. Günümüzde finansman ve muhasebe alanlarındaki uygulamalar ve işlemler makine öğrenmesi sayesinde çok hızlı bir şekilde gerçekleştirilmektedir. Makine öğrenmesi araçlarını ve tekniklerini sistemlerine entegre eden şirketler fırsatları ve faydaları öngörüp, paydaşlarına sağlanan potansiyel faydaları iletebilir ve işletmelerine bu bağlamda rekabet avantajı sağlayabilir. Çok sayıda belirsizliklerin olduğu dinamik bir sektörde geleceğin öngörülmesi işletmelerin karlılıklarına önemli derecede katkı sağlayacaktır. Makine öğrenmesi hem finansman hem muhasebe alanında kullanılmakta olan uygulamalara en etkin şekilde destek olmaktadır.



## KAYNAKÇA

- Ali, Zulqurnain; Gongbing, Bi, “*Does Supply Chain Finance Improve SMEs Performance? The Moderating Role of Trade Digitization*”, University of Science and Technology of China, 2020.
- Bakar, Nashirah Abu; Rosbi, Sofian, “*Autoregressive Integrated Moving Average (ARIMA) Model for Forecasting Cryptocurrency Exchange Rate in High Volatility Environment: A New Insight of Bitcoin Transaction*”, International Journal of Advanced Engineering Research and Science (IJAERS), s.135, 2017.
- Baranes, Amos, Palas, Rimona, “*Earning Movement Prediction Using Machine Learning Support Vector Machines (SVM)*”, Journal of Management Information and Decision Sciences, Vol.22, Iss. 2, s.36-53, 2019.
- Beasley, M., “*An empirical analysis of the relation between board of director composition and financial statement fraud*”, The Account Review, 71 443-466, 1996.
- Bouri, E., Gkillas, K., Gupta, R., ve diğ., “*Forecasting realized volatility of bitcoin: The role of the trade war*”, Computational Economics, 2020.
- Bracke, Philippe; Datta, Anupam; Jung, Carsten; Sen, Shayak, “*Machine Learning Explainability in Finance: an Application to Default Risk Analysis*”, Bank of England, 2019.
- Bussmann, Niklas; Giudici Paolo, “*Explainable Machine Learning in Credit Risk Management*”, Computational Economics, 2020.
- Chakraborty, T., Chakraborty, A. K., Biswas, M., ve diğ., “*Unemployment rate forecasting: A hybrid approach*”, Computational Economics, 2020.
- Chen, Ting Hsuan, “*Do you know your customer? Bank risk assessment based on machine learning*”, Applied Soft Computing, 2020.
- Chimonaki, C., Papadakis, S., Vergos, K., Shahgholian, A., “*Identification of financial statement fraud in Greece by using computational intelligence techniques*”, Liverpool John Moores University, 2019.
- Choi, Dahee; Lee, Kyungho, “*An Artificial Intelligence Approach to Financial Fraud Detection under IoT Environment: A Survey and Implementation*”, Korea University, 2018).

- Chowdhury, Raetz; Rahman, M. Arifur; Rahman, M. Sohel; Mahdy, M.R.C, “*An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning*”, Physica, 2020.
- Cullinan, P. G., Sutton, G. S., “Defrauding the public interest: a critical examination of reengineered audit processes and the likelihood of detecting fraud”, *Critical Perspectives on Accounting*, 13, 297–310, 2002.
- Danenas, P., Garsva, G., “SVM and XBRL Based Decision Support System for Credit Risk Evaluation”, 17th International Conference on Information and Software Technologies, s.190-198., 2011.
- Dbouk, Bilal; Zaarour Iyad, “*Towards a Machine Learning Approach for Earnings Manipulation Detection*”, *Asian Journal of Business and Accounting* 10(2), 2017.
- Demirel, Uğur, “*Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları ile Tahmini*”, Gümüşhane, 2019.
- Duarte, D., Barboza F., “*Forecasting Financial Distress With Machine Learning*”, *FutureJournal*, 2020.
- Eweoya I.O., Adebisi A.A., Azeta, A.A., Amosu, Olufunmilola, “*Fraud Prediction in Loan Default Using Support Vector Machine*”, IOP Publishing, 2019.
- Fanning, K., & Cogger, K., “Neural network detection of management fraud using published financial data. *International Journal of Intelligent Systems in Accounting*”, *Finance & Management*, 7(1), 21–24. 1998.
- Gaber, C., Hemery, B., Achemlal, M., Pasquet, M., & Urien, P., “*Synthetic logs generator for fraud detection in mobile transfer services*”, *International Conference on Collaboration Technologies and Systems* (pp. 174–179), 2013.
- Gan, Lirong; Wang, Huamao; Yang, Zhaojun, “*Machine Learning Solutions to Challenges in Finance: An Application to the Pricing of Financial Products*”, “*Technological Forecasting and Social Change*”, 2020.
- Geylan, Feyza, “*Kurumsal Performans Analizi ve Bir Uygulama*”, İstanbul Üniversitesi, İstanbul, 2007.

- Giudici, Paolo, “*Fintech Risk Management: A Research Challenge for Artificial Intelligence in Finance*”, *Frontiers in Artificial Intelligence*, 2018.
- Gogas, Periklis; Papadimitriou Theophilos, “*Machine Learning in Economics and Finance*”, *Computational Economics*, 2021.
- Hajek, Petr; Henriques, Roberto, “Mining corporate annual reports for intelligent detection of financial statement fraud – A comparative study of machine learning methods”, *Knowledge Based Systems*, 2016.
- Henrique, B. M., Sobreiro, V. A., Kimura, H., “Literature review: Machine learning techniques applied to financial market prediction”, *Expert System with Applications*, Volume 124, Pages 226-251, 2019.
- Hipgrave, Shaun, “Smarter fraud investigations with big data analytics”, 2013.
- Hogan, C.E., Rezaee, Z. Riley, R.A, Velury, U.K., “*Financial Statement Fraud: Insights from the Academic Literature*”, *Auditing: A Journal of Practice & Theory*, Pages 231-252, 2008.
- Jordan, M. I., Mitchell, T. M., “*Machine Learning: Trends, Perspectives and Prospects*”, *Science* Vol: 349, Issue: 6245, pp. 255-260, 2015.
- Kalaycı, Sacide, “*Makine Öğrenmesi Yöntemleri ile Kredi Risk Analizi*”, İstanbul Teknik Üniversitesi, 2018.
- Kanmaz, Medet, “*The Effect of Financial News on BIST Stock Prices: A Machine Learning Approach*”, Middle East Technical University, 2018.
- Karaduman, İsmet, “*The effect of XBRL and artificial intelligence using auditing process in accounting audit and expert systems application*”, Kocaeli Üniversitesi, 2017.
- Kim Y.B., Kim J.G., Kim W., Im J.H., Kim T.H., Kang S.J., Kim C.H., “*Predicting Fluctuations in Cryptocurrency Transactions Based on User Comments and Replies*”, *Plos One* 11, 2016.
- Kirkos, Efstathios, Spathis, Charalambos, Manolopoulos, Yannis, “*Data Mining techniques for the detection of fraudulent financial statements*”, *Expert Systems with Applications* 32, 2007.

- Kuenkaikaew, S., Vasarhelyi, M., “*The Predictive Audit Framework*”, International Journal of Digital Accounting Research”, 2013.
- Kumar, M. R., Chakravarthy, V. Deeban, ve diğ., “*Personal Finance Transaction Index Scoring Using Machine Learning Model*”, Materialstoday: Proceedings, 2021.
- Lee, In; Shin, Yong Jae, ”*Machine Learning for Enterprises: Applications, Algorithm Selection and Challenges*”, Kelley School of Business, 2020.
- Lopez-Rojas, E. A. Axelsson, S., “*A review of computer simulation for fraud detection research in financial datasets*”, Future Technologies Conference (pp. 932–935), 2016.
- Lussange, J. Lazarevich, I., Bourgeois-Gironde, S., ve diğ., “*Modelling stock markets by multi-agent reinforcement learning*”, Computational Economics, 2021.
- Mantegna, R.N., Stanley, H.E., “*Introduction to econophysics: Correlations and Complexity in Finance*”, Cambridge University Press, 1999.
- Meng, Bo, “*Corporate Finance and Machine Learning*”, The University of Iowa, 2018.
- Mulvey, J.M., “*Machine Learning and Financial Planning*”, IEEE Potentials, 36, pp.8-13, 2017. • Murdoch, W. James; Singh, C; K., Abbasi-Asl, R., & Yu, B., “*Definitions, Methods and Applications in Interpretable Machine Learning*, Proceedings of the National Academy of Sciences, 2019.
- Porter, B., Cameron, A., “*Company fraud—what price the auditor?*”, Accountant’s Journal(December), 44–47. , 1987.
- Ryll, Lukas; Seidens, Sebastian, “*Evaluating the Performance of Machine Learning Algorithms in Financial Market Forecasting: A Comprehensive Survey*”, Cornell University, 2019.
- Sadgali, Imane; Sael, Nawal; Benabbou, Fanouzia, “*Performance of machine learning techniques in the detection of financial frauds*”, The First International Conference On Intelligent Computing in Data SciencesAt: Fez-Morroco Volume: Volume 148, Pages 45-54, 2019.

- Sayana, S.A. “*Using CAATs to support IS audit*”, Informations Systems Control Journal, 1, 1-3, 2003.
- Sayım, Kadir, “*Yapay Zeka Teknikleri İle Yatırım Değerlemesi Analizi*”, Doktora Tezi, Gebze Teknik Üniversitesi, Gebze, 2018.
- Sharma, A., Panigrahi, K.P., “*A Review of Financial Accounting Fraud Detection Based on Data Mining Techniques*”, International Journal of Computer Applications”, Pages 37-47, 2012.
- Site, Atakan, “*Stock Market Prediction Using Machine Learning Models*, Dokuz Eylül University, 2020.
- Soybilgen, B., Yazgan, E., “*Nowcasting US GDP Using Tree-Based Ensemble Models and Dynamic Factors*”, Computational Economics, 2020.
- Spathis, C., Doumpos, M., & Zopounidis, C., “*Using client performance measures to identify pre-engagement factors associated with qualified audit reports in Greece*”. The International Journal of Accounting, 38, 267–284, 2003.
- Spiegelcer, J. “*Machine Learning for Quantitative Finance: Fast Derivative Pricing, Hedging and Fitting*”, Quantitative Finance, 2018.
- Triebels, R., Daniels, H., Berndsen, R., “*Monitoring liquidity management of banks with recurrent neural networks*”, Computational Economics, 2020.
- Tsagris, M., “*A new scalable Bayesian network learning algorithm with applications to economics*”, Computational Economics, 2020.
- Wyrobek, Joanna, “*Application of Machine Learning Models and Artificial Intelligence to Analyze Annual Financial Statements to Identify Companies with Unfair Corporate Culture*”, Cracow University of Economics, Poland, 2020.
- Yang, Hongtao, “*Venture Capital Decision Based on FPGA and Machine Learning*”, Microprocessors and Microsystems, 2020.
- Yazgan, Ege; Soybilgen, Barış, “*Nowcasting US GDP Using Tree-Based Ensemble Models and Dynamic Factors*”, Istanbul Bilgi University, 2020.

- Yıldız, Birol; Ağdeniz, Şafak, “*A Comparative Study of Machine Learning Algorithms as an Audit Tool in Financial Failure Prediction*”, TİDE Academia Research, 2019.
- Yılmaz, F. M.; Arabacı, O., “Should deep learning models be in high demand, or should they simply be a very hot topic? A comprehensive study for exchange rate forecasting, *Computational Economics*, 2020.
- Yılmaz, Veysel, “*Finansmanı Öğrenen Makineler*”, Gaziosmanpaşa Üniversitesi, Tokat, 2019. • Yoon, Jaehyun, “*Forecasting of Real GDP Growth Using Machine Learning Models: Gradient Boosting and Random Forest Approach*”, *Computational Economics*, 2021.
- Zhu, You; Zou, Li; Wang, Gang-Jin; Nguyen, Truong V., “*Forecasting SMEs’ credit risk in supply chain finance with an enhanced hybrid ensemble machine learning approach*”, *International Journal of Production Economics*”, 2019.
- <https://www.fsb.org/wp-content/uploads/P011117.pdf>, “Artificial Intelligence and Machine Learning in Financial Services”, 2017. Son Erişim Tarihi: 10.07.2021.

