

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
İŞLETME BİLİM DALI

MAKİNE ÖĞRENMESİ YÖNTEMİ İLE
SATIŞ TAHMİNLEMESİ

DOKTORA TEZİ

İlknur PAKSOY

İstanbul
Mayıs, 2026

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
İŞLETME BİLİM DALI

MAKİNE ÖĞRENMESİ YÖNTEMİ İLE
SATIŞ TAHMİNLEMESİ

DOKTORA TEZİ

İlknur PAKSOY

Danışman
Prof. Dr. Ömer TORLAK

İstanbul
Mayıs, 2026

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından İşletme Anabilim Dalı, İşletme Bilim Dalı'nda DOKTORA TEZİ olarak kabul edilmiştir.

Danışman Prof. Dr. Ömer TORLAK (İmza)

Üye Prof. Dr. Özgür KÖKALAN (İmza)

Üye Dr. Öğr. Üyesi Fahrettin ÇAKIR (İmza)

Üye Prof. Dr. Yasemin BAL (İmza)

Üye Dr. Öğr. Üyesi Rıfğı Buğra BALCI (İmza)

Onay

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

Doç. Dr. Ali Hakan ÇAVUŞOĞLU
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİMİ

Doktora tezi olarak hazırladığım “**Makine Öğrenmesi Yöntemi ile Satış Tahminlemesi**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

İlknur PAKSOY

ÖNSÖZ

Doktora eğitimim ve tez çalışmam süresince bilgi birikimi ve yol göstericiliği ile çalışmamın şekillenmesinde büyük katkı sağlayan, pazarlama alanındaki derin tecrübesiyle bana her zaman rehber olan kıymetli tez danışmanım Sayın Prof. Dr. Ömer TORLAK hocama en içten teşekkürlerimi sunarım.

Tez sürecimin her aşamasında özellikle de tez konumun seçiminde bilgi ve tecrübelerini benimle paylaşan, her daim ulaşılabilir olarak destek ve motivasyonunu esirgemeyen Sayın Prof. Dr. Özgür KÖKALAN hocama şükranlarımı sunarım.

Doktora sürecim boyunca katkıları, önerileri ve değerli geri bildirimleri ile çalışmamın olgunlaşmasına destek olan Sayın Dr. Öğr. Üyesi Fahrettin ÇAKIR'a ve araştırmamın özellikle uygulama ve analiz bölümlerinde sağladığı değerli akademik desteği ve yönlendirmeleri ile çalışmamın sonuca ulaşmasına önemli katkı sağlayan Sayın Dr. Ahmet HEREKOĞLU'na teşekkürlerimi sunarım.

Bu uzun ve yoğun süreçte anlayışı ve desteğiyle yanımda olan eşim Abdullah PAKSOY'a ve her daim manevi desteğiyle arkamda olan anneme teşekkür ederim.

Geleceğe dair en büyük motivasyon kaynağım olan canım çocuklarım Serra Betül ve Mustafa Emir'e de onların zamanından alarak çalışma yaptığım her dakika için kalpten teşekkür ederim.

İlknur PAKSOY

İstanbul, 2026

ÖZET

MAKİNE ÖĞRENMESİ YÖNTEMİ İLE SATIŞ TAHMİNLEMESİ

İlknur PAKSOY

Doktora, İşletme

Tez Danışmanı: Prof. Dr. Ömer TORLAK

Mayıs, 2026, 88+xi Sayfa

Bu çalışma, veri odaklı yapay zekâ uygulamaları çerçevesinde süpermarket satış verileri üzerinden makine öğrenmesi yöntemleri ile yüksek doğruluklu satış tahminlemesi yapmayı amaçlamaktadır. Perakende sektöründe geleneksel istatistiksel yöntemlerin büyük veri hacmi ve karmaşık tüketici davranışları karşısında yetersiz kalması, işletmeleri daha analitik ve genellenebilir çözümlere yöneltmektedir. Araştırmanın temel problemi, mevsimsellik ve trend gibi sınırlı değişkenlerle talep dinamiklerini modellemenin güçlüğüdür.

Araştırma kapsamında, İstanbul'un farklı konumlarında faaliyet gösteren süpermarketlerin 2021-2023 yıllarını kapsayan 1.180.402 satırlık veri seti kullanılmıştır. Yöntem olarak XGBoost, Random Forest ve LightGBM algoritmaları tercih edilmiş; modelleme sürecine promosyon etkileri, stok seviyeleri ve takvim değişkenlerini içeren 27 farklı öznelik entegre edilmiştir. Modellerin geleceği öngörme performansı, zaman serisi disiplinine uygun olan "Hareketli Pencere Doğrulaması" (Rolling Window Validation) yöntemiyle test edilmiştir.

Araştırma bulguları, XGBoost modelinin mevcut veriyi açıklama gücünün yüksek olduğunu (R^2 : 0,9654), ancak operasyonel tahminleme başarısında LightGBM modelinin %7,23 MAPE değeri ile daha stabil ve güvenilir sonuçlar sunduğunu ortaya koymuştur. Özellik önem analizi sonucunda, satış cirosunu etkileyen en kritik değişkenin "fiziki işlem hacmi" olduğu ve bunu kısa dönemli gecikmeli satış verilerinin takip ettiği saptanmıştır. Sonuç olarak, makine öğrenmesi yöntemlerinin perakende sektöründe stratejik pazarlama ve stok kararları için bilimsel temelli, özgün bir çerçeve sunduğu kanıtlanmıştır.

Anahtar Kelimeler: Makine Öğrenmesi, Satış Tahmini, Perakende Sektörü, LightGBM, XGBoost

ABSTRACT
SALES FORECASTING WITH MACHINE LEARNING
METHOD

İlknur PAKSOY

Ph.D., Dissertation, Business Administration

Thesis Advisor: Prof. Dr. Ömer TORLAK

May, 2026, 88+xi Pages

This study aims to develop high-accuracy sales forecasting models using machine learning methods over supermarket sales data within the framework of data-driven artificial intelligence applications. The failure of traditional statistical methods in the face of large data volumes and complex consumer behaviors in the retail sector necessitates more analytical and generalizable solutions for businesses. The primary problem addressed is the difficulty of modeling demand dynamics with limited variables such as seasonality and trends.

The research uses a dataset of 1,180,402 rows covering 2021-2023 from supermarkets across various locations in Istanbul. XGBoost, Random Forest, and LightGBM algorithms were selected as methods, and 27 different features, including promotion effects, stock levels, and calendar variables, were integrated into the modeling process. The models' forecasting performance was evaluated using the 'Rolling Window Validation' method, which is well-suited to time-series data.

The research findings revealed that while the XGBoost model had high explanatory power for existing data (R^2 : 0.9654), the LightGBM model provided more stable and reliable results in operational forecasting with a 7.23% MAPE value. Feature importance analysis identified "physical transaction volume" as the most critical variable affecting sales turnover, followed by short-term lagged sales data. Consequently, it has been proven that machine learning methods offer an original, science-based framework for strategic marketing and inventory decisions in the retail sector.

Keywords: Machine Learning, Sales Forecasting, Retail Sector, LightGBM, XGBoost.

İÇİNDEKİLER

TEZ ONAYI	i
BİLİMSEL ETİK BİLDİRİMİ.....	II
ÖNSÖZ.....	III
ÖZET.....	IV
ABSTRACT	V
İÇİNDEKİLER	vi
TABLO LİSTESİ	IX
ŞEKİL LİSTESİ.....	X
KISALTMA LİSTESİ	XI
BİRİNCİ BÖLÜM	
GİRİŞ	1
1.1.Tezin Konusu	3
1.2. Araştırma Yöntemi.....	4
1.3. Tezin Düzeni	5
İKİNCİ BÖLÜM	
PERAKENDECİLİK VE SATIŞ TAHMİN YÖNTEMLERİ.....	6
2.1. Satış ve Satış Yönetimi	6
2.2. Perakendecilik Kavramı ve Yapısal Özellikleri.....	9
2.3. Tüketici Davranışları ve Satış Tahminlemesine Etkisi	10
2.4. Satış Tahmini Kavramı	14
2.5. Talep Tahmin Kavramı	15
2.6. Geleneksel Tahmin Yöntemleri	17
2.6.1. Niceliksel Yöntemler.....	17
2.6.1.1. Zaman Serileri	17
2.6.1.2. Korelasyon ve Regresyon.....	18
2.6.2. Niteliksel Yöntemler	19

2.6.3. Hibrit (Niteliksel ve Niceliksel) Yöntemler	21
2.6.4. Yapay Zeka Destekli Tahminler.....	22
2.6.4.1. Yapay Sinir Ağları (Artificial Neural Networks).....	22
2.6.4.2. Derin Öğrenme (Deep Learning)	23
2.6.4.3. Bulanık Mantık (Fuzzy Logic)	24
2.6.4.4. Hibrit Yapay Zekâ Modelleri	24
2.7. Makine Öğrenmesine Geçiş	24

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ.....	26
3.1. Makine Öğrenmesi Nedir.....	26
3.2. Makine Öğrenmesi Terminolojisi	29
3.3. Makine Öğrenmesi Türleri.....	30
3.3.1. Gözetimli Öğrenme (Sınıflandırma ve Regresyon).....	30
3.3.1.1. K-En Yakın Komşu.....	31
3.3.1.2. Karar Ağaçları	32
3.3.1.3. Rastgele Orman	33
3.3.1.4. Lojistik Regresyon	34
3.3.1.5. Destek Vektör Makinesi.....	35
3.3.1.6. Naiye Bayes.....	35
3.3.1.7. Lineer Regresyon	36
3.3.1.8. Çoklu Lineer Regresyon.....	37
3.3.1.9. XGBoost (Extreme Gradient Boosting)	38
3.3.1.10. LightGBM (Light Gradient Boosting Machine)	39
3.3.2. Gözetimsiz Öğrenme	39
3.3.2.1. Kümeleme (Clustering)	40
3.3.2.2. Boyut İndirgeme (Dimensionality Reduction).....	41
3.3.2.3. Bağıntı Kurma	42

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMA	45
4.1. Araştırmanın Amacı ve Özgün Değeri.....	45
4.2. Yöntem.....	46
4.2.1. Veri Setinin Tanımı ve Keşifsel Veri Analizi	47

4.2.2. Veri Ön İşleme Süreçleri	51
4.2.2.1. Eksik Verilerin Yönetimi	51
4.2.2.2 Aykırı Değer Analizi	52
4.2.2.3. Tatil ve Özel Günlerin Modele Entegrasyonu.....	55
4.3. Bulgular ve Tartışma.....	56
4.3.1. Özellik Mühendisliği Uygulamaları (Feature Engineering).....	56
4.3.1.1. Birinci Aşama: Takvim Tabanlı Özelliklerin Oluşturulması	56
4.3.1.2. İkinci Aşama: Zaman Serisi Tabanlı Özelliklerin Oluşturulması	56
4.3.1.3. Özellikler Mühendisliği Sürecinin Özeti.....	56
4.3.2. Model Kurulumu ve Hiperparametre Optimizasyonu	59
4.3.3. Model Performans Değerlendirmesi	60
SONUÇ	68
5.1. Bulguların Literatürle Karşılaştırılması	68
5.2. Modelde Öne Çıkan Değişkenlerin Pazarlama Açısından Değerlendirilmesi	68
5.3. Modelin Güçlü Yönleri ve Sınırlılıkları.....	69
5.4. Araştırmacılar ve Uygulamacılara Öneriler	70
5.5. Nihai Değerlendirme	70
KAYNAKÇA	72
EKLER.....	88
EK - 1: Özgeçmiş	88

TABLO LİSTESİ

Tablo 3.1: Makine Öğrenmesi Temel Kavramları ve Açıklamaları	28
Tablo 3.2: Yapılan Benzer Çalışmalar.....	44
Tablo 4.1: Değişkenlerin Adlandırılması.....	49
Tablo 4.2: Değişkenlerin Türlerine Göre Adlandırılması.....	50
Tablo 4.3: Veri Setindeki Eksik Değerler	51
Tablo 4.4: IQR Yöntemine Göre Bulunan Değerler	52
Tablo 4.5: Veri Setine Ait Değerler	53
Tablo 4.6: XGBoost ve RF Modellerinin Performans Karşılaştırması.....	60
Tablo 4.7: XGBoost ve LightGBM Modellerinin Performans Karşılaştırması.....	62

ŞEKİL LİSTESİ

Şekil 4.1: Stok Değişkenine Ait Eksik Veri Oranı	51
Şekil 4.2: Satış Ciroosu Değişkenine Ait Kutu Grafiği (Box Plot).....	53
Şekil 4.3: Satış Ciroosu Değişkenine Ait Frekans Dağılımı	54
Şekil 4.4: Satış Ciroosunun Zaman Serisi Görünümü.....	54
Şekil 4.5: Tatil Günleri ve Haftanın Günlerine Göre Satış Ciroosu Analizleri.....	55
Şekil 4.6: Değişkenler Arası Korelasyon Matrisi.....	57
Şekil 4.7: Satış Ciroosu Zaman Serisinin Ayrıştırılması (Trend, Mevsimsellik ve Artık Bileşenler).....	58
Şekil 4.8: Mağaza, Zaman ve Promosyon Değişkenlerine Göre Satış Ciroosu Analizleri	61
Şekil 4.9: Kategori ve Ana Grup Bazında Satış Ciroosu Analizleri.....	62
Şekil 4.10: Modellerin Hata Metrikleri ve R^2 Skoru Açısından Karşılaştırılması...	63
Şekil 4.11: Modelde Kullanılan Değişkenlerin Önem Dağılımı	64
Şekil 4.12: Rolling Window Validation Sonuçları: Hata Metrikleri ve Gerçek–Tahmin Karşılaştırması.....	65
Şekil 4.13: LightGBM Modeli için Gerçek–Tahmin Karşılaştırması ve Hata Analizleri	66
Şekil 4.14: Satış Ciroosunun Günlük, Aylık ve Yıllık Trend Analizi.....	67

KISALTMA LİSTESİ

AIDA	: Attention (Dikkat Çekme), Interest (İlgi Uyandırma), Desire (İstek Uyandırma), Action (Harekete Geçme)
BTK	: Bilgi Teknolojileri Kurumu
Et al.	: Ve diğerleri
GRU	: Gated Recurrent Unit
KNN	: K-Nearest Neighbors
LightGBM	: Light Gradient Boosting Machine
LSTM	: Long Short-Term Memory
Ed.	: Editör
FMTS	: Fixed Model Time Series
ML	: Machine Learning
OMTS	: Open Model Time Series
PCA	: Temel Bileşen Analizi
RF	: Random Forest
XGBoost	: Extreme Gradient Boosting
Vd.	: Ve diğerleri
YSA	: Yapay Sinir Ağları

BİRİNCİ BÖLÜM

GİRİŞ

Perakende sektörü üretici ve tüketici arasındaki en kritik noktalardan biridir ve ekonomik sistem içerisinde çok önemli bir rolü bulunmaktadır (Öztürk, 2013). Daha önceki yıllarda küçük işletmelerin ya da yerel esnafların müşterileriyle doğrudan ve kişiselleştirilmiş ilişkileri vardı. Ancak günümüze doğru gelindiğinde işletmelerin daha büyük ölçekli olduğu, süpermarketlerin ve zincir marketlerin hâkimiyetinin fazlaştığı karmaşık bir yapıyla karşılaşmaktadır. Bu durum beraberinde çeşitli müşteri profillerini ve yönetilmesi gereken çok büyük hacimli verileri getirmiştir (Wu ve Olson, 2020). Bahsi geçen büyük ölçekli işletmelerdeki satış süreçleri yalnızca ürün arzına bağlı olarak şekillenmeyip promosyon uygulamaları, mağaza konumuna göre işlem yoğunluğu, mevsimsel dalgalanmalar, stok durumu ve tüketici davranışlarındaki değişimler gibi birçok faktöre göre farklılık göstermektedir. Buna rağmen birçok perakende işletmecisi gelecek dönem satış tahmini, stok yönetimi ve işletme stratejilerini belirleme çalışmaları yaparken geleneksel yöntemlere başvurmaktadır. Bunun sonucunda da finansal planlama, kampanya dönemlerini belirleme, stok kontrolü, karar alma süreçleri gibi operasyonel faaliyetlerde işletmelerin verimliliğini düşürmektedir (Eroğlu ve Bayraktar Köse, 2020).

İşletmeler açısından talebin doğru tahmini çok kritik bir faktördür. Rekabet üstünlüğü ve kâr marjını büyütmek için maliyetlerine dikkat etmeleri gereken her işletme için stok yönetimi çok önemlidir. Diğer yandan, tam tersi durum olan stoklarda eksik kalma da müşteri memnuniyetini azaltan ve satış kayıplarına sebebiyet veren bir unsurdur (Acı ve Ayyıldız Doğanşoy, 2022). Bu sebepten ötürü satış tahmini sadece istatistiki bir analiz değil, stratejik kararlar alma hususunda bir karar destek aracı olarak değerlendirilmelidir.

Konuyla ilişkili literatürde yer alan çalışmalarda veri hacminin artışı, satışı etkileyen değişkenlerin çok sayıda oluşu gibi faktörler tahmin analizlerinde genelleme noktasında sınırlamalar oluşturmuştur (Hyndman ve Athanasopoulos, 2021). Bu durum gittikçe daha esnek, fazla sayıdaki değişkenlere duyarlı, büyük veri kapasitesi

ile kolaylıkla ve hızlı bir şekilde çalışabilen yöntemlere olan ihtiyacı artırmıştır. Makine öğrenmesi algoritmaları tam bu noktada daha fazla kullanılmaya başlanmıştır. Çünkü büyük veri setlerini inceleyebilme kabiliyeti ve çok değişkenli karmaşık örüntüleri modelleyebilmesi, günümüz işletmelerinde satış tahmini problemlerini çözümlemeyi kolaylaştırmıştır (Makridakis et al., 2018).

Bu çalışmanın amacı da süpermarket satış verileri üzerinden makine öğrenmesi algoritmaları ile yüksek doğruluklu bir satış tahmin modeli geliştirmektir. Bu modele etki eden değişkenler sadece geçmiş satış verileri değil; stok durumu, promosyon dönemleri, mağaza içi işlem sayısı, mağaza büyüklüğü ve konumu, tatil etkileri ve mevsimsellik gibi çok boyutlu özellikleri de kapsamaktadır. Makine öğrenmesi yöntemlerinin çok sayıda değişkeni aynı anda değerlendirebilme kapasitesi sayesinde perakende satışların dinamik yapısını anlamada büyük kolaylık sağlayacaktır. Bu da literatürde sıkça vurgulanan veri temelli karar alma yaklaşımlarının işletme performansına olumlu etki sağlayacağı görüşünü desteklemektedir (Brynjolfsson, Hitt & Kim, 2011).

Satış tahmini üzerine yapılmış olan çalışmaların birçoğunda tek bir algoritma üzerinden veya daha sınırlı veri seti ile analizlerin gerçekleştirildiği görülmektedir. Oysaki bu tezde çok sayıda değişkenin etkisiyle gerçekleşen karmaşık bir yapının olduğu ve operasyonel faktörlerin etkisiyle geliştirilmesi gereken bir yöntemler zincirine ihtiyaç duyulduğu açıktır. Yaklaşık 1,18 milyon gözlemden oluşan veri setine sahip bu çalışma birden fazla makine öğrenmesi yöntemiyle en yüksek doğruluk veren model seçimini hedeflemiştir. Veri ön işleme çalışmaları, özellik mühendisliği, hiperparametre optimizasyonları ve zaman bazlı doğrulama yöntemleri ile kapsamlı bir modelleme süreci yürütülmüştür.

Bu tezde, perakende satış tahminlemesi yaparken literatüre iki temel açıdan fayda sağlanması hedeflenmiştir. İlki büyük hacimli verilerle makine öğrenmesi algoritmalarının performanslarının analizi yoluyla yöntemlere dair bir perspektif sunulması, ikincisi ise stok, kampanya dönemleri, fiziki işlem sayıları ve takvime bağlı değişimler ele alınmak suretiyle satış tahminine dönük bütüncül bir yaklaşımın ortaya konulmasıdır.

1.1. Tezin Konusu

Bu çalışma veri odaklı yapay zekâ uygulamaları çerçevesinde, süpermarket satış verileri üzerinden makine öğrenmesi yöntemleri ile satış tahminlemesi yapmayı amaçlamaktadır. Geçmiş dönemlerde işletmelerin genel olarak küçük ölçekli oluşu, müşteri ilişkilerinin daha kişiselleştirilmiş ve hedefe yönelik bir düzeyde tutulmasına olanak tanımaktaydı. Büyük ölçekli perakendeciler yerine yerel esnafların ve küçük işletmelerin çoğunlukta olması, müşteriyle yakın ilişkiler kurarak alışveriş alışkanlıklarının doğrudan gözlemlenmesini ve müşteri ihtiyaçlarına daha hızlı ve etkili bir şekilde yanıt verilebilmesini mümkün kılmaktaydı (Wu & Olson, 2020). Ancak zaman içinde küçük işletmeler büyüyerek ulusal veya uluslararası düzeyde faaliyet gösteren büyük perakende zincirlerine dönüşmesiyle hem müşteri sayıları artmış hem de müşteri profilleri daha karmaşık hale gelmiştir. Çok sayıda şubeye sahip büyük perakende zincirleri, müşterilerinin bireysel tercihlerini, satın alma davranışlarını ve gereksinimlerini anlamlandırma konusunda giderek artan zorluklar yaşamaktadır (Meyer ve Schwager, 2007).

Günümüzün yoğun rekabet ortamında, perakende sektörü sürekli değişim göstermekte ve satış tahminleme süreçleri giderek karmaşık ve çok boyutlu hale gelmektedir (Sinap, 2024). Bu açıdan birçok süpermarket yıllık satışlarını tahmin etmekte zorlanmaktadır. Bu durum büyük ölçüde satış tahmini gerçekleştirmek için gerekli uzmanlık, altyapı ve analitik bilgi yetersizliğinden kaynaklanmaktadır. Bununla birlikte süpermarketler, gelecek dönem satışlarını öngörmek ve değerlendirmek amacıyla genellikle sistematik olmayan yöntemler ve geçici çözümler kullanmaktadır (Eroğlu ve Bayraktar Köse, 2020: 428). Geleneksel yöntemler diye nitelendirilen bu çözümler yetersiz kaldığından, gelişen teknolojilerin beraberinde getirdiği modern teknikler, özellikle makine öğrenmesi tabanlı yöntemler, önemli bir rol üstlenmektedir.

Süpermarketler satış tahminlerinde geleneksel istatistiksel yaklaşımları kullanmaya devam etseler de, veri miktarındaki hızlı artış karşısında bu yöntemler doğruluk ve genellenebilirlik açısından yetersiz kalarak güvenilir sonuçlar üretme kapasitelerini kaybetmektedir. Özellikle mevsimsellik, trend vb. sınırlı değişkenlerle tüketici davranışlarını dinamik ve çok boyutlu olarak modellemek çok mümkün olmamaktadır (Hyndman & Athanasopoulos, 2021). Bu çalışmada farklı makine öğrenmesi algoritmaları ile çok sayıda değişken içeren ve dalgalı dönemlerde dahi en optimum

doğrulukla çalışan satış tahminlemesi sonuçlarına yer verilmesi amaçlanmıştır. Bu noktadan yola çıkarak, makine öğrenmesi yöntemleri ile süpermarketlerin satış tahminlemesi uygulamaları sonucunda elde edilen bulgular, tahminleme süreçlerinin iyileştirilmesinde ve veri temelli stratejilerin belirlenmesinde değerli bir rehberlik sağlayacaktır (Nacar, 2021).

Bu çalışmanın özgünlüğü, sadece niceliksel bir tahminleme sunmakla kalmayıp, satış tahminine entegre edilen fiyat değişimleri, dönemsel taleplerdeki dalgalanmalar, promosyonların etkisi, ürün kategorilerindeki farklılıklar, ürünlerin satıldığı süpermarketlerdeki teşhir alanları, zamanlama açısından doğru miktarlarda stok bulundurması gibi değişkenlerle veri temelli bir karar sistemi sunmasıdır. Bu sistem makine öğrenmesi algoritmaları ile ölçülebilir hale getirilmektedir. Bunun sonucunda da tahminlerin gerçeğe yakınlık oranının geleneksel yöntemlere göre artırılması hedeflenmiştir.

Bu yönüyle tez, literatürde sınırlı sayıda bulunan makine öğrenmesi tabanlı satış tahminleme çalışmalarına katkı sunmakta ve geleneksel yöntemlerin sonuçlarını daha ileriye taşıyarak pazarlama kararlarında bilimsel temelli özgün bir çerçeve önermektedir.

1.2. Araştırma Yöntemi

Kısa vadeli tahminler üretim planlaması, stok ve envanter yönetimine yardımcı olurken, uzun vadeli tahminler ise pazarlama stratejileri, yatırım planlaması ve kurumsal büyümeyi destekler. Makine öğreniminin temel amacı, veri toplama, istatistiki ve matematiksel yöntemleri kullanarak geçmiş verilerden öğrenme yeteneği ile çıktıları tahmin etmede öngörülerde bulunabilen algoritmalar ve modeller oluşturmaktır (Koh, Joseph, & Sivakumar, 2024).

Yapay zekanın bir alt alanı olan makine öğrenmesi (ML), verilerden ve deneyimlerden öğrenerek belirli görevlerdeki performanslarını artırmak için bilgisayar programlarını eğitmeye odaklanır. Satış tahminlemesine yönelik çok sayıda yöntem vardır ve şirketler tarihsel olarak gelecekteki satış ve talep tahminleri için doğrusal regresyon, zaman serisi analizleri, özellik mühendisliği ve rastgele orman gibi istatistiksel ve makine öğrenmesi tabanlı modellere odaklanmaktadır (Odegua, 2020).

Makine öğrenimi, sağladığı yüksek tahmin doğruluğu ve öngörü kabiliyeti sayesinde veri bilimi alanında giderek daha fazla önem kazanmakta olup birçok kritik uygulama alanının yanında hassas satış tahminleri gerçekleştirmek için de yaygın biçimde kullanılmaktadır. Makine öğrenimi modelleri, geçmişteki verileri belirli kalıplar ile öğrenir ve ileride gerçekleşecek olayları doğru bir şekilde tahmin etmek için öngörülerde bulunur. Başarılı bir tahmin modeli, süpermarket gelirini büyük ölçüde artırmasına katkı sunabilir ve aynı zamanda kârlılığı, müşteri memnuniyetini, hizmet kalitesini de olumlu yönde etkileyebilir (Brynjolfsson, Hitt & Kim, 2011).

1.3. Tezin Düzeni

Tez 5 bölümden oluşmaktadır. Giriş kısmını içeren birinci bölümde tezin konusu, araştırma yöntemi ve tezin düzeninden bahsedilmektedir. İkinci bölümde perakende satış, tüketici davranışı ve geleneksel tahmin yöntemleri konuları çerçevesinde başlıklar sunulmuştur. Üçüncü bölümde ise tezin araştırma yöntemi olan makine öğrenmesinin kavramsal terminolojisi ve yöntem türleri ele alınmıştır. Sonraki bölümde ise araştırma bulguları ve tartışma kısmı bulunmaktadır. Makine öğrenmesi türleri arasından en doğru sonuca götüren yöntem/yöntemler belirlenecektir. Araştırmada elde edilen bulgular, teorik bir çerçevede değerlendirilecek ve sonuçları kapsamlı bir biçimde tartışılacaktır.

İKİNCİ BÖLÜM

PERAKENDECİLİK VE SATIŞ TAHMİN YÖNTEMLERİ

Perakende sektöründe satış tahminlemesi yapmak yıllardır işletmelerin en kritik analiz süreçlerinden biridir. Geleneksel tahmin yöntemleri denilen istatistiki modeller, geçmişteki satış eğilimlerine, uzman görüşlerine veya zaman serisi analizleri gibi tekniklere dayanmaktadır. Bu modeller çoğu zaman tüketici karar süreçlerindeki karmaşıklıkları ve çok boyutlu etkileri açıklamakta yetersiz kalmaktadır (Makridakis, Wheelwright & Hyndman, 1998). Özellikle promosyon dönemleri, süpermarketin konumu ve teşhir alanı büyüklüğü, özel günler ve tüketiciyi etkileyen psikolojik duygular gibi farklı faktörlerin satın alma davranışına etkisini açıklamada geleneksel yöntemlerin sınırlı kaldığı görülmektedir. Bu bağlamda literatürde, istatistiki yöntemlerin verdiği gerçekleşme oranlarının yüksek değişkenlik gösteren ürün gruplarında düşük kaldığı, beklenmeyen talep durumlarını tahmin etmekte güçlük yaşadığı belirtilmektedir (Hyndman & Athanasopoulos, 2021). Ayrıca tüketicinin psikolojik, çevresel ve durumsal faktörlerin etkisiyle satın alma kararlarının eğilimleri bu yöntemlerde modele dahil edilememektedir.

Bu tez kapsamında, satış tahminlemesi yaparken, makine öğrenmesi tabanlı tahmin modelleri kullanılarak çok boyutlu bir şekilde ele alınmaktadır. Tüketicinin satın alma kararına etki eden faktörler modele entegre edilerek, promosyonlu ürün grupları, bu ürünlerin kategorileri, süpermarketin konum ve teşhir alanları, geçmiş satış verileri ve stok miktarları gibi etkenlerle ürün/ürün gruplarının doğru zamanda, doğru miktarda ve doğru noktada bulunmasını sağlayan daha yüksek gerçekleşme oranına sahip bir tahminleme sistemi oluşturulmaktadır. Yapılan araştırmalarda perakende ve hızlı tüketim ürünlerinde makine öğrenmesi algoritmalarının tahmin doğruluğunu belirgin bir şekilde artırdığı görülmüştür (Fry & Steele, 2020; Martín et al., 2022).

2.1. Satış ve Satış Yönetimi

Pazarlamanın öğelerinden biri olan satış, günümüzde pazarlama süreçleri ile bütünleşmiş ve sınırları neredeyse kalmayarak iç içe geçmiştir. Satış, kısaca, insanları

bir ürün veya hizmeti satın almaya ikna süreci olarak tanımlanabilir. Bu süreçte insanlar almak istedikleri hizmet veya ürüne, uygun zamanda, uygun bir biçimde ve uygun bedelle sahip olma eğilimindedir (İslamoğlu ve Altunışık, 2007: 25-26). Satış, alıcı ile satıcı arasında ihtiyaç ve beklentiler için ortak bir nokta bulunmasıyla gerçekleşir. Satış süreci aşamaları, hedef müşteri potansiyeline dönük araştırmaya başlanması, ön hazırlık çalışmaları, müşteri ihtiyaç tespitinin yapılması, ürün veya hizmetlerin sunumu, müşterilerden gelen itirazların karşılanması, satışın kapatılması ve satış sonrası takibin gerçekleştirilmesi şeklindedir.

Satış süreci geleneksel olarak yedi aşamadan oluşmaktadır: müşteri adayı belirleme, satış öncesi hazırlık, yaklaşım, sunum, itirazların ele alınması, satışın kapatılması ve satış sonrası takip. Günümüzde ise bu süreç daha ilişkisel bir yapıya dönüşmüştür ve müşteri ilişkileri yönetimi yaklaşımı çerçevesinde şekillenmektedir. Modern satış sürecinde müşteri adayı belirleme yerine ilişkisel veritabanları kullanılmakta, satış öncesi hazırlık yerine müşteri değer yönetimi, yaklaşım yerine ise ilişki kurma gibi daha stratejik adımlar yer almaktadır (Moncrief ve Marshall, 2005: 16).

Bu gelişen satış sürecinde başarılı olmak için satış personelinin çeşitli beceriler geliştirmesi gerekmektedir. Satış sürecinde uyumlu satış davranışı, satış elemanının farklı müşteri türleri ve satış durumlarına göre satış yaklaşımını değiştirme yeteneği olarak tanımlanmaktadır. Bu yaklaşım, müşteri beklentilerini daha iyi karşılama ve satış başarısını artırma potansiyeline sahiptir. Uyumlu satış, satış elemanının sahip olduğu çeşitli satış sunum tekniklerini etkileşim halinde olduğu müşteriye uyarlama becerisine dayanmaktadır (Spiro ve Weitz, 1990: 62).

Uyumlu satış davranışının yanı sıra, etkili bir satış süreci için yaratıcılık da büyük önem taşımaktadır. Satış sürecinde yaratıcılık, müşterilerin benzersiz ihtiyaçlarını karşılamak için yeni çözümler ve yaklaşımlar geliştirme becerisidir. Yaratıcı satış performansı, satış elemanının müşteri sorunlarına yenilikçi çözümler sunabilme ve farklı satış yaklaşımları geliştirebilme kapasitesini ifade etmektedir. Bu yaratıcılık, özellikle karmaşık satış durumlarında rekabet avantajı sağlamaktadır (Wang ve Netemeyer, 2004: 806).

Bütün bu süreçlerin etkili bir şekilde yürütülebilmesi için satış personelinin kendine olan güveni kritik bir faktördür. Satış sürecinde, satış elemanının uyumlu satış güveni de önemli bir faktördür. Bu güven, satış elemanının farklı müşteri ve durumlarla başa

çıkabilme konusundaki özgüvenini yansıtır. Uyumcu satış güveni yüksek olan satış elemanları, müşteri ihtiyaçlarını daha iyi tespit edebilmekte ve daha etkin satış sunumları gerçekleştirebilmektedir (Román ve Iacobucci, 2010: 370).

Satış yönetimi, müşterilerin ihtiyaç ve beklentilerini göz önüne alarak, ürün veya hizmet ile ilgili sorularını cevaplandırmayı, neden tercih edilmesi gerektiği ile ilgili açıklama yapmayı ve genel özelliklerini etkili bir biçimde sunmayı kapsayan bir süreçtir. Bu sürecin en önemli amacı müşteriyi ikna etmek ve ona güven vermektir. Literatürde bu süreç, bazı araştırmacıların kabulüyle AIDA modelinin dört adımı ile gerçekleşmektedir. Dikkat çekme (Attention), ilgi uyandırma (Interest), istek uyandırma (Desire) ve harekete geçme (Action) şeklinde sıralanmaktadır (Wijaya, 2012). Son aşama olan “Action” boyutunun müşterinin fiili davranışını temsil ettiği belirtilmektedir (Kotler & Keller, 2016).

Satış yönetimi, bir organizasyonun ticari hedeflerine ulaşabilmesi adına satış operasyonlarının stratejik bir çerçevede ele alınmasıdır. Bu süreç genel olarak; stratejik planlama, operasyonel uygulama ve sonuçların analiz edildiği denetim aşaması olmak üzere üç temel boyutta incelenmektedir. Karafakioğlu (2012), bu sürecin başarılı bir şekilde yürütülmesini; yetkin satış personelinin seçilip eğitilmesine, bu personelin motivasyonunun yüksek tutulmasına, doğru müşteri kitlesinin hedeflenmesine ve tüm satış faaliyetlerinin yakından takip edilmesine dayandırmaktadır.

Genel bir perspektifle bakıldığında, satış yönetimi; satış gücü faaliyetlerinin planlanmasından organizasyonuna, temsilcilerin temininden bu ekibin sevk, idare ve kontrolüne kadar geniş bir yönetim alanını kapsar. Konuyu daha kapsamlı bir tanıma dayandıran Barutçu ve Sezgin (2012) ise satış yönetimini; satış ekibinin belirli amaçlar doğrultusunda seçilmesi, eğitilmesi, bölgelere atanması ve ücretlendirilmesi gibi operasyonel süreçlerin yanı sıra, motivasyon yönetimi ve performans değerlendirmesi gibi denetimsel unsurları da içeren bütünsel bir süreç olarak ifade etmektedir.

Satış yönetiminin temel amacı ise müşteri ihtiyaçlarını karşılarken organizasyonun satış hedeflerine ulaşmasını sağlamaktır. Etkili satış yönetimi için satış yöneticilerinin dönüşümcü liderlik özellikleri göstermeleri gerekmektedir. Dönüşümcü liderlik tarzını benimseyen satış yöneticileri, satış ekibinin performansını ve motivasyonunu olumlu yönde etkilemektedir (Panagopoulos ve Avlonitis, 2010: 48).

Satış yönetimi sürecinde satış gücü kontrolü de önemli bir unsurdur. Satış gücü kontrolü, satış elemanlarının davranışlarını ve sonuçlarını izleme, değerlendirme ve düzeltici önlemler alma faaliyetlerini kapsamaktadır. Davranış odaklı kontrol ve sonuç odaklı kontrol olmak üzere iki temel kontrol mekanizması bulunmaktadır. Davranış odaklı kontrol, satış elemanlarının satış sürecindeki faaliyetlerini yönlendirmeye odaklanırken, sonuç odaklı kontrol satış performansının nihai sonuçlarını değerlendirmeye yöneliktir (Baldauf, Cravens ve Piercy, 2005: 8).

2.2. Perakendecilik Kavramı ve Yapısal Özellikleri

Perakendecilik kavramı, ürün ya da hizmetin nihai tüketiciye ulaştığı son nokta şeklinde açıklanabilir. Bu sürecin tamamlanmasıyla ticari döngünün son aşaması da yerine getirilmiş olmaktadır (Öztürk, 2013). İşletmeler bu aşamayı fiziksel mağazalar ile tamamlamaktadır. Ürün ve hizmetlerini sunarken tüketici taleplerine göre satış stratejilerini belirleyen işletmeler, satış alanlarını ve hizmetlerini sunma şekillerini bu doğrultuda seçerler (Aytekin ve Aydınocak, 2022). Perakendeciliğe örnek verecek olursak, hipermarketler kapsamlı ürün çeşitliliği sunmakta, buna karşın süpermarketler daha sınırlı satış alanlarıyla faaliyet göstermektedir. Daha küçük ölçekli işletmeler olan marketler ve bakkallar kıyaslandığında ise, marketlerin bakkallardan daha zengin ürün çeşitliliğine ve daha geniş teşhir alanlarına sahip olduğu görülmektedir (Orel Demirci, 2003).

Perakendecilik türlerinden olan franchising ise marka adı, dağıtım hakları, satış yetkisi gibi ayrıcalıkların karşı tarafa verilmesi olarak tanımlanabilir. İsmi kullanılan kuruluş açısından bir dağıtım yöntemi olarak gözükmekle, franchisee kullanan alıcı tarafından bir iş kurma veya yatırım biçimidir (Demirci 1993: 54). Bir başka perakendecilik şekli ise zincir mağazalardır. Ülkede çok sayıda ve farklı büyüklükteki şubeleriyle hizmet veren, yönetiminin bir genel merkezden yapıldığı işletmelerdir. Zincir mağazalar, üretimi yapılmayan ürünleri diğer üreticilerden alımlar yaparak tüketici ve üretici arasındaki aracılığı kaldıran perakendeci kuruluşlardır (Cengiz ve Özden, 2002).

Perakendeciler ürün alıp satmanın yanı sıra, tüketicilere yer, mülkiyet, zaman faydası ve ürün çeşitliliği sunmak gibi işlevleri de yerine getirmektedir. Ayrıca stok tutma, tüketicilere yönelik destek sağlama ve bilgi paylaşımında bulunma gibi çeşitli görevleri de yerine getirmiş olmaktadır (Levy & Weitz, 2004:9). Perakendeciler

tüketicinin ihtiyaç duyduğu ürünleri en uygun yerde ve zamanda, aracısız bir şekilde tüm ürün çeşitleriyle sunmaktadır. Aynı zamanda etkili stok yönetimi sayesinde tüketicilerin isteklerini eksiksiz olarak gidermeyi amaçlamaktadır (Khan et al., 2005).

Perakendeciler, satış sürecinde ve sonrasında dikkat edilmesi gereken hususları tüketiciyle paylaşarak ve tüketicinin de ürün çeşitliliği ve fiyatlandırmaya ilişkin konularındaki geri bildirimlerini, istek ve önerilerini dikkate alarak karşılıklı bilgi paylaşımında bulunmaktadırlar. Perakende sektöründe rekabet fazla olduğundan sektöre dair dinamikler sürekli değişmektedir (Oluç, 1989). Müşteri beklentilerindeki değişimlere göre stratejilerini, hizmet politikalarını ve operasyonel süreçlerini sık sık revize etmektedirler.

2.3. Tüketici Davranışları ve Satış Tahminlemesine Etkisi

Tüketici, en kısa ifadeyle, ürün ya da hizmeti satın alan ve bunu kullanan kişiye denir. Daha geniş açıklamak gerekirse, ihtiyacı olan veya beğendiği ürün ya da hizmetlere sahip olmak için tercih yapabilen, yaptığı tercihleri karşılayabilecek ekonomik kaynaklara sahip olan ve tüm bunların sonucunda da fayda sağlayıp tatmin olan kişidir (Kıyak, 2024).

Günümüzde tüketici kavramı ekonomik ve toplumsal etkenler dolayısıyla daha da önemli bir konu haline gelmiştir. Tüketici ve tüketici davranışlarına verilen önem, müşteri odaklılık kavramını işletmelerin merkezine almasını gerektirdiği açıkça görülmektedir. Müşteri odaklı olma, ihtiyaç ve talepleri doğru okuyarak iyi ürün veya hizmeti uygun fiyatla sunmanın yanı sıra, bu hizmet veya ürünün çeşitli ödeme seçenekleri ile ekonomik açıdan müşterinin alım gücünü kolaylaştırmayı da kapsamaktadır (Şahin 2016:61).

Öte yandan, tüketiciler rasyonel ve irrasyonel olmak üzere iki ana kategoride incelenebilmektedir. Rasyonel tüketiciler, fayda maksimizasyonu prensibine dayalı olarak hareket ederken, irrasyonel tüketiciler duygusal, ani ve plansız satın alma davranışları sergileyebilmektedir. Bu iki tüketici tipinin satın alma karar süreçleri ve davranış kalıpları farklılık gösterdiği söylenebilir (Foxall, 2010: 45).

Bir başka açıdan bakıldığında, günümüzde tüketici davranışlarında değişim yaşanmaktadır. Özellikle dijitalleşme ve teknolojik gelişmeler tüketicilerin bilgiye

erişim şekillerini ve satın alma davranışlarını önemli ölçüde etkilemiştir (Darley, Blankson ve Luethge, 2010: 95). Bu çerçevede, tüketici davranışlarını şekillendiren faktörler arasında kültürel, sosyal, psikolojik ve kişisel etkenler yer almaktadır. Kültürel faktörler, toplumun temel değer yargılarını, algılamalarını, tercihlerini ve davranışlarını etkilemekte ve tüketici tercihlerinde belirleyici rol oynamaktadır. Özellikle alt kültür grupları ve sosyal sınıflar tüketicilerin satın alma davranışlarında farklılaşmaya neden olmaktadır (Cleveland et al., 2016). Sosyal faktörler incelendiğinde, referans grupları, aile, rol ve statü gibi unsurların tüketici davranışlarını etkilediği görülmektedir (Shareef et al., 2019: 57).

Tüketici davranışları, satın alma öncesi, satın alma ve satış sonrası gibi birtakım faaliyetlerden oluşmaktadır. Bu süreçte fiziksel faaliyetler ile bu faaliyetleri etkileyen karar verme mekanizmaları çok önemlidir. Tüketicilerin neyi, ne zaman, nereden, hangi yolla ve neden aldıklarını açıklamak için bir bütün olarak bu unsurlar göz önüne alınmalıdır (Arslan ve Yavuz, 2020).

Tüketiciler satın alma davranışlarını sadece kendi ihtiyaçlarını gidermek için gerçekleştirmezler. Aile, sosyal çevre, gelir durumu gibi dış etkenlerin de etkisi altındadır (Acar ve Torlak, 2022: 46-61). Tüketicilerin satın alma davranışlarının çok yönlü bir şekilde analiz edilmesi, işletmelerin büyüme ve kârlılıklarını artırma politikaları açısından doğru bir strateji izlemeleri açısından oldukça önemlidir.

Satın alma karar süreci, değişen çevre ve rekabet koşullarında işletmeler için derinlemesine araştırılması ve anlaşılması gereken bir konu haline gelmiştir (Yağcı ve İlarıslan, 2010: 138). Pazarlama alanı için tüketicilerin karar alma davranışlarını incelemek ve bu sürecin işleyişini iyi bir şekilde anlamak, işletmelerin kullanacakları en etkili yöntemlerin belirlenmesi adına çok önemlidir. Literatürde genellikle beş aşamada gerçekleştiği görülen satın alma karar süreci; ihtiyacın fark edilmesiyle başlar, satın alma sonrasındaki davranışların bütününe kapsayarak sonlanır (Comegys et al., 2006).

İhtiyacın ortaya çıkması:

Satın alma karar sürecinde ilk aşama bireyin ihtiyacını fark etmesiyle başlar. İhtiyacın ortaya çıkmasındaki sebep, içsel veya dışsal uyarıcılar ile haz ve fayda amaçlı beklentiler etkisiyle olabilir. Aynı zamanda ihtiyaca yönelik satın alma eyleminin gerçekleşmesini etkileyen başka unsurlar da bulunmaktadır. Yaş, cinsiyet, ürün ve

hizmetin bulunabilirliği, çevresel koşullar ve psikolojik faktörler bu unsurlara örnek olarak sayılabilir (Erciş vd., 2007).

Öte yandan günümüzde, modern tüketim toplumunda ihtiyaçların ortaya çıkışı giderek daha karmaşık bir hal almıştır. Tüketiciler, gerçek fizyolojik ihtiyaçların yanı sıra, sosyal medya ve dijital pazarlama kanallarından gelen sürekli uyaranlara maruz kalmaktadır. Bu durum, gerçek ihtiyaçlar ile arzular arasındaki sınırı bulanıklaştırmaktadır. İhtiyacın ortaya çıkması aşamasında, tüketicilerin çözüm arayışına girmelerini tetikleyen mevcut durumları ile arzu ettikleri durum arasındaki ayrımın farkına varmaları kritik öneme sahiptir (Hodkinson, 2019).

Seçeneklerin Aranması:

Tüketiciler ihtiyaçlarını gidermek için ürün veya hizmetlerle ilgili bilgi toplama arayışına girerler. Bu süreçte tüketiciler satın almayı düşündükleri ürün veya hizmeti araştırarak reklamlara ve diğer dikkat çeken tanıtım unsurlarına göre ilk değerlendirmelerini yaparlar. Sonrasında daha derinlemesine bilgi edinme aşamasına geçerek aktif bir şekilde yorumları ve kullanıcı deneyimlerini okuma ve farklı model, marka ve ürün alternatiflerini karşılaştırma aşamasına gelmektedirler (Talih, 2013).

Seçeneklerin Değerlendirilmesi:

Bu aşamada tüketiciler birden çok alternatif ürün ya da hizmet arasından önem, beklentilerini karşılama ve fayda derecesine göre bir seçim yapmaktadır (Erdemir, 2017). Ayrıca geçmiş tecrübeleri ve güvenilir kaynakların tavsiyeleri de tercih sebeplerinde etkili olmaktadır (Öztürk, 2017:60)

Ayrıca, tüketiciler seçenekleri değerlendirirken çeşitli bilişsel önyargılar ve sezgisel kısayollar kullanmaktadır. Örneğin, yakın zamanda çok vurgulanan veya kolay hatırlanabilen ürün özelliklerine aşırı ağırlık verilmesi yaygın bir değerlendirme eğilimidir (King et al., 2014).

Satın Alma Kararı:

Tüketici ürün veya hizmetle ilgili değerlendirmeleri sonucunda ihtiyacına yönelik en uygun seçenek üzerinde karar verme davranışı göstermektedir. Ancak satın alma niyeti ile satın alma kararı farklı kavramlardır. Satın alma niyeti bir ürün veya hizmeti alma eğilimi, düşüncesi veya planlaması anlamını taşıırken, bu niyetin somut bir davranışa dönüşen haline ise satın alma kararı denilebilir (Erdemir, 2017). Tüketici satın alma

niyeti aşamasında, ürün veya hizmeti alıp almamaya ya da alacaksa fiyatı, markası, cinsi, rengi, zamanı, nereden alacağı vb. hususlara karar verir (Öztürk, 2017: 60).

Satın Alma Sonrası Değerlendirme:

Tüketicinin satın alma kararından sonra ürün veya hizmetten beklediği performans ile yaşadığı deneyim arasındaki fark memnuniyet düzeyini göstermektedir. Bu memnuniyet düzeyi, sadece tüketici açısından değil, firmalar açısından da büyük önem teşkil etmektedir (Comegys et al., 2006). Çünkü ürün veya hizmetten memnun kalan tüketicide yeniden satın alma isteği ve marka sadakati oluşturacaktır. Hatta başkalarına tavsiye ederek gönüllü tanıtım elçisi olarak görev almasını da beraberinde getirecektir. Tüm bu sebeplerden ötürü bu kavram firmaları yakından ilgilendirmektedir (Talih, 2013).

Öte yandan tüketici davranışlarındaki değişimler çok yönlü yapısı ve karmaşık çevresel etmenler ile etkileşime açık olması nedeniyle anlaşılması ve tahmin edilmesi zor olmaktadır. Bir tüketici, farklı zamanlarda, değişen şartlar ve psikolojik etkenler dolayısıyla farklı satın alma tercihleri sergileyebilmektedir (Arslan ve Yavuz, 2020).

Bu nedenle günümüzde perakende satış ortamlarında ortaya çıkan bu karmaşık ve çok değişkenli tüketici davranış biçimlerini geleneksel istatistiki yöntemlerle açıklamak yetersiz kalmaktadır. Bunun temelinde, tüketici davranışının etkileşimli ve yüksek boyutlu bir veri yapısında olmasıdır (Lilien, Rangaswamy & De Bruyn, 2017). Bu çalışmanın araştırma yönetimi olan makine öğrenmesi algoritmaları bu noktada çok sayıda veriden faydalanarak tüketici davranışlarına ilişkin örüntüleri öğrenebilmekte ve geleceğe ilişkin satış tahmin modellerini önemli ölçüde ortaya koymaktadır.

Makine öğrenmesi algoritmaları, promosyon, geçmişteki alışveriş alışkanlıkları, ürün grupları, mağaza teşhir alanı ve mevsimsellik gibi çok sayıda faktör arasındaki bağlantıyı aynı modelde örüntüleyebilmektedir. Buradan yola çıkarak tüketicinin satın alma davranışını etkileyen değişkenlerin etkisini daha doğru tahmin edebilmektedir (Martín, García & Sánchez, 2022). Örneğin, Random Forest ve Gradient Boosting modelleri faktörlerin satış tahminine katkı düzeyini ölçebilmektedir. Bu sayede değişkenlerin önem düzeyleri ile tüketici davranışlarını ve satın alma kararlarını şekillendirerek modelleyebilmektedir (Hastie, Tibshirani & Friedman, 2009).

2020 yılında Walmart'ın satış verileriyle yapılan M5 yarışması, özellikle perakende satış tahmini üzerine odaklanmıştır. Satış tahmini literatüründe en güncel ve en güçlü

karşılaştırma sayılabilecek bu yarışmanın sonuçları, tüketici davranışına ilişkin çok değişkenli yapıyı öğrenebilen makine öğrenmesi yöntemleri içerisinde özellikle XGBoost ve LightGBM gibi metotların geleneksel yöntemleri önemli ölçüde geride bıraktığını ve daha iyi performans sergilediğini göstermiştir (Makridakis, Spiliotis & Assimakopoulos, 2020).

Bu bağlamda tüketici davranışına ilişkin literatür ile makine öğrenmesi algoritmalarıyla yapılan satış tahminlemesi arasındaki ilişki ortaya konmuştur. Sonuç olarak, tüketici karar süreçlerindeki değişkenlerin eğitim veri setine entegre edilmesi, makine öğrenmesi tahmin modellerinin gerçeğe uygunluğunu artırmakta; böylece fiyatlandırma, promosyon planı ve stok belirleme gibi operasyonel karar süreçlerinde işletmeler için önemli bir veri sağlamaktadır.

2.4. Satış Tahmini Kavramı

Satış tahmini, belirli çevresel koşulların dikkate alınarak gelecekteki talebin öngörülmesi sürecini ifade eder. Bu tahminler, nitel (kalitatif) veya nicel (kantitatif) yöntemler aracılığıyla yapılabilmektedir. Satış planı ise işletmenin stratejik hedefleri doğrultusunda satış faaliyetlerinin gerçekleşme düzeyinin belirlenmesi amacıyla, satış tahminlerini temel alarak oluşturulmaktadır (Demirtaş ve Özcan 2020).

İşletmelerde satış tahmini yapılmasının çeşitli gerekçeleri bulunmaktadır. Satış tahminleri aşağıdaki maddelerde belirtilen hususların gereği olarak belirli dönemlerde güncellenmelidir.

- Pazarlama yöneticilerinin ürün veya ürün grupları için fiyatlandırma, promosyon faaliyetleri ve mağaza yerleşim kararlarını alabilmeleri,
- Satış yöneticilerinin satış bölgeleri ve satış gücü doğrultusunda planlama yapabilmeleri,
- Finans yöneticilerinin maliyet, kârlılık düzeyi ve operasyonlar için gerekli sermayeyi planlayabilmeleri,
- Üretim yöneticilerinin iş gücü, hammadde ve ekipman ihtiyaçlarını zamanında programlayabilmeleri,
- Tedarik yöneticilerinin üretimden mağazalara dağıtım sürecini organize edebilmeleri.

Etkin bir satış tahmini gerçekleştirebilmek için üç temel bilgi grubuna ihtiyaç duyulmaktadır. Bunlardan ilki, içsel verilerdir; satış hacmi, fiyat değişimleri ve promosyon etkileri bu kapsamda değerlendirilmektedir. İkincisi, işletmenin gelecekte uygulamayı planladığı pazarlama ve tedarik stratejileridir. Üçüncü bilgi grubu ise pazarı doğrudan etkileyebilecek ekonomik, politik ve kültürel faktörleri içeren dışsal verilerdir (Bolt, 1994).

İçsel veriler, farklı yöntemlerle analiz edilerek geçmiş ve güncel performans bilgisine dönüştürülebilmektedir. Bu süreçte çeşitli gruplama tekniklerinden yararlanılmaktadır. Başlıca yöntemler şu şekilde özetlenebilir:

- **Satış Hacmi Analizi:** Belirli bir ürün ya da ürün grubunun toplam satış miktarı ile karşılaştırılması sonucunda, işletmenin toplam gelire yaptığı katkı ölçülmektedir.
- **Coğrafi Bölgeye Göre Satış Hacmi:** Gerçekleşen satışlar ile potansiyel satışlar karşılaştırılarak her bir bölgenin performansı değerlendirilmektedir.
- **Zaman Periyoduna Göre Satış Hacmi:** Belirli zaman aralıklarında satış dalgalanmaları incelenerek mevsimsellik, fiyat değişimleri, promosyon faaliyetleri ve reklam etkileri ortaya konulmaktadır.
- **Satış Kanalına Göre Satış Hacmi:** Ürünlerin farklı dağıtım ve satış noktalarındaki performansları karşılaştırılarak en yüksek kârlılığı sağlayan kanal belirlenmektedir.

Bu gruplama teknikleri kullanılarak elde edilen geçmiş satış performansları korelasyon analiziyle incelenmeli ve elde edilen sonuçlar doğrultusunda satış tahminleri yapılmalıdır (Sevgi, 2012).

2.5. Talep Tahmin Kavramı

Tüketiciler açısından, yokluğunda gerilime sebebiyet veren durum ihtiyaç olarak tanımlanırken, kültürel yapı, kişilik özellikleri ve çevresindeki etkenler ile şekillenen biçimi ise istek olarak adlandırılır. Tüketicilerin satın alma gücüyle desteklenmiş, potansiyel olarak almaya hazır olduğu isteklere de talep denilmektedir (Yücesoy, 2011).

Talep tahmini, bir ürünün gelecek bir zaman dilimi içerisinde tüketiciler tarafından gerçekleşecek olan alımların öngörülmesidir. Satış tahmini, talep tahminleme sürecinin bir çıktısıdır (Özdemir ve Özdemir, 2006).

Talep tahmini perakende sektöründe çok önemli bir role sahip bir süreçtir. Özellikle piyasa koşullarının sürekli değiştiği ortamlarda talebin öngörülememesi, stok fazlalığı ya da stokta ürünün bulunmaması nedeniyle tedarik ve depolama süreçlerinde birçok probleme neden olur. Bu tür aksaklıklar müşteri memnuniyetinin zedelenmesi ve müşteri kaybı ile neticelenmektedir (Acı ve Ayyıldız Doğansoy, 2022). Bu yüzden firmaların temel amacı, müşteri taleplerini minimum zamanda ve doğru faaliyetlerle karşılayarak müşteri memnuniyetini artırmak ve kâr marjını yükseltmektir (Yücesoy, 2011).

Tahmin problemleri seçilen zaman dilimine göre kısa, orta ve uzun dönemli olmak üzere 3'e ayrılmaktadır. Günlük ve haftalık planlar kısa dönemli olup envanter yönetimi ve üretim planlarını oluşturma gibi kararların verilmesinde kullanılmaktadır. Orta dönemli tahminler ise haftalık ve aylık planlardır. Satış modeli ve kampanya planlarının oluşturulmasında, çalışan ihtiyaç ve kaynaklarının belirlenmesinde, yani iş gücü ve kapasite yönetiminde, haftalık veya aylık planlar kullanılmaktadır (Saatçioğlu ve Özçakar, 2016). Uzun dönemli tahminler ise yıllık, hatta daha uzun dönemleri kapsar. İşletmelerin üretim stratejilerini etkileyen kapasite artırımı veya azaltımı kararları, yeni teknoloji kaynaklarına yönelim, çalışan sayısındaki değişimler, mali kaynak dağılımı vb. faktörlerin belirlenmesi ve tüm bu değişikliklere hazırlık aşamalarına dair öngörüler uzun dönemli tahminlerdir (Yılmaz, 2020).

Son yıllarda yapay zekâ ve makine öğrenmesi tekniklerinin yaygınlaşmasıyla, talep tahmininde yeni yaklaşımlar geliştirilmektedir. Özellikle makine öğrenmesi modelleri, geleneksel istatistiksel yöntemlere kıyasla daha yüksek doğruluk oranları sağlayabilmektedir. Bu modeller, büyük miktarda yapılandırılmamış veriyi işleyerek karmaşık talep modellerini tanımlayabilmekte ve beklenmedik değişimlere hızlı adaptasyon gösterebilmektedir (Bandara et al., 2020).

2.6. Geleneksel Tahmin Yöntemleri

Geleneksel tahmin yöntemleri başlığı kapsamında, niceliksel yöntemler, niteliksel yöntemler, hibrit niceliksel ve niteliksel yöntemler ve yapay zekâ destekli tahminler yer almaktadır.

2.6.1. Niceliksel Yöntemler

Niceliksel yöntemler başlığı altında, zaman serileri ile korelasyon ve regresyon analizi başlıkları yer almaktadır.

2.6.1.1. Zaman Serileri

Zaman serileri yöntemi, yalnızca geçmiş dönemlere ait verilerden yararlanarak gelecekteki satışların tahmin edilmesine dayanmaktadır. Bu yöntem, tarihsel satış verilerinin belirli desenler doğrultusunda analiz edilmesiyle öngörüler sunar. Şekil 3.1’de de görüldüğü üzere zaman serilerinin temel bileşenleri şu şekilde açıklanabilir:

- Seviye (Level): Satışların sabit olduğu, trend, sezonsallık veya rassal dalgalanma (gürültü) içermeyen durumda, zaman ufkuna göre gözlenen ortalama değeri ifade eder.
- Trend: Satışların belirli bir zaman aralığında sürekli artış veya azalış eğilimi göstermesidir. Bu eğilim doğrusal veya eğrisel bir yapı sergileyebilir.
- Sezonsallık: Yılın belirli dönemlerinde tekrarlayan, mevsimsel faktörlerden kaynaklanan düzenli artış veya azalışları ifade etmektedir.
- Gürültü: Açıklanamayan ve öngörülemeyen rassal dalgalanmalardır. Satış verilerindeki bu düzensizlikler genellikle modele dâhil edilemeyen faktörlerden kaynaklanır.

Bu bileşenlerin analiz edilmesi, geçmiş verilerden hareketle geleceğe yönelik daha gerçekçi ve güvenilir satış tahminleri yapılmasına olanak tanımaktadır (Sevgi, 2012).

Zaman serisi yöntemleri genel olarak iki temel grupta incelenmektedir. Bunlardan ilki açık model zaman serileridir (Open Model Time Series – OMTS), diğeri ise sabit model zaman serileridir (Fixed Model Time Series – FMTS). OMTS yaklaşımında, örneğin Box-Jenkins yöntemi gibi tekniklerle öncelikle zaman serilerinin bileşenleri

analiz edilmekte, ardından uygun bir model oluşturularak geleceğe yönelik tahminler yapılmaktadır. Ancak bu yöntemin bazı sınırlılıkları bulunmaktadır. Öncelikle, OMTS tekniklerinin uygulanabilmesi için yöntemlerin eğitilmesi gerekmekte ve uzun dönemlere ait geniş satış verilerine ihtiyaç duyulmaktadır. Ayrıca, tahminlerin doğruluk derecesi büyük ölçüde analizi gerçekleştiren kişinin deneyim ve yetkinliğine bağlıdır. Bu nedenlerle OMTS teknikleri, satış tahminlerinde sınırlı bir kullanım alanına sahip olmaktadır (Kara ve Kök, 2019).

Bu yöntem satış tahminlemede en sık başvuru geleneksel yaklaşımlardan biridir. Seviye, trend, sezonsallık ve gürültü gibi bileşenlerle modellenmesi, verinin zamana bağlı olarak tahmin edilip anlaşılmasına olanak sağlamaktadır. Ancak zaman serisi yaklaşımında model çoğunlukla tek değişkenli yapılar oluşup satışları etkileyen çok boyutlu değişkenleri modele entegre edememektedir (Makridakis, Spiliotis & Assimakopoulos, 2018). Bu nedenle, sadece satışların geçmiş hareketlerini kullanarak tahminleme yaparken, dışsal değişkenlerin satış etkilemesini modele dahil etmede yetersiz kalmaktadır. Bu sınırlılık, makine öğrenmesi tabanlı algoritmalarının daha iyi tahmin performansı ortaya koymasının nedenlerini açıklamaktadır.

2.6.1.2. Korelasyon ve Regresyon

Korelasyon ve regresyon yöntemleri, satışlar ile çeşitli dışsal faktörler arasındaki ilişkilerin incelenmesine dayanmaktadır. Bu yöntemlerde amaç, reklam, promosyon veya fiyat indirimi gibi unsurların satışlar üzerindeki etkilerini ortaya koymaktır. Sağlıklı tahminler yapılabilmesi için hem geçmiş satış verileri gibi içsel bilgilerden hem de dışsal faktörlere ilişkin verilerden yararlanılması gerekmektedir (Alpar, 2022).

Öncelikle, belirlenen faktörler ile satışlar arasındaki korelasyon katsayısı hesaplanmalı ve bu ilişkinin gelecekte de benzer şekilde devam edeceği varsayılmalıdır. Bu yöntem, temelde zaman serisi analizine benzemekle birlikte, dışsal faktörlerin etkilerinin eklenmesiyle daha kapsamlı tahminler yapılmasına olanak tanır. Ancak tekniğin önemli bir dezavantajı, geniş hacimli verilere ihtiyaç duymasıdır; özellikle en az altı aylık veri seti gereklidir (Büyüköztürk, 2023). Bu bağlamda satış tahminlerinde kullanılabilecek dışsal faktörler şu şekilde sınıflandırılabilir:

- **Resmi kaynaklardan elde edilen veriler:** Devlet kurumları tarafından sağlanan istatistikler, müşteri potansiyelinin sosyoekonomik özelliklerine göre gruplandırılmasına imkân tanır. Yaş, cinsiyet, eğitim düzeyi, gelir durumu gibi göstergeler dikkate alınarak geçmiş, mevcut ve gelecekteki talep koşullarına ilişkin tahminler yapılabilir.
- **İlave kaynaklardan elde edilen veriler:** Araştırma firmaları tarafından yürütülen anketler veya özel araştırmalar yoluyla sağlanan verilerdir. Bu tür bilgiler, satış tahminlerinin daha güvenilir ve detaylı şekilde yapılmasına katkı sağlar (Alpar, 2022).

Regresyon ve korelasyon analizlerinin temel varsayımları gerçek hayattaki perakende verilerinde çoğu zaman karşılık bulmamaktadır. Öte yandan, bu yöntem karmaşık, doğrusal olmayan ilişkileri yeterince açıklayamamakta; çok sayıdaki bağımsız değişkeni olan büyük veri yapılarında düşük performans sergilemektedir (Hastie, Tibshirani & Friedman, 2009). Bu sebeple bu analizlerin sunduğu açıklayıcı modelin ilerisine geçerek, değişkenler arasında karmaşık ilişkileri öğrenip modelleyebilen makine öğrenmesi yöntemlerine ihtiyaç duyulmaktadır.

2.6.2. Niteliksel Yöntemler

Niteliksel yöntemler, satışların geçmiş dönemlerdeki davranışlarının gelecekte de benzer şekilde tekrarlanacağı varsayımına dayanmaktadır (Karagöz, 2021). Bu yöntemlerin doğruluk düzeyi büyük ölçüde tahminleri yapan kişinin uzmanlığına bağlıdır. Niteliksel yöntemlerin aşağıdaki durumlarda kullanılması daha güvenilir sonuçlar vermektedir:

- Niceliksel yöntemlerle yapılan tahminlerin sonrasında ince ayarlamaların yapılmasında,
- Çok çeşitli ürün portföyü veya kurumsal düzeyde tahmin gerektiğinde,
- Henüz geçmiş satış verisi olmayan yeni ürünlerin piyasaya sürülmesi durumunda.

Tahmin sürecinde genellikle öncelikle niceliksel yöntemler kullanılır ve ardından düzeltmeler için niteliksel, subjektif yaklaşımlar uygulanır. Başlıca niteliksel yöntemler şunlardır:

- Firma İçi Uzmanlık (In-house Expert): Pazar dinamikleri ve satış faktörleri hakkında derin bilgiye sahip kilit uzmanlar, bazı durumlarda niceliksel yöntemlerden daha doğru tahminler üretebilir. Bu kişiler pazarın, müşterinin, ürün kalitesinin ve çevresel faktörlerin satışlar üzerindeki etkilerini değerlendirebilir. Firma içi uzmanlık özellikle ince ayarlama (fine-tuning) aşamasında kullanılabilir. Dezavantajı, uzman kişinin firmadan ayrılması durumunda bilgi boşluğu oluşabilmesidir.
- Uzman Komite (Executive Committee): Bu yöntemde, firmanın farklı bölümlerinden (finans, pazarlama, satış, üretim ve tedarik) uzmanlar bir araya gelerek tahminler oluşturur. Komitenin değerlendirmeleri, niceliksel hesaplamalar için başlangıç noktası sağlar ve gerekirse niceliksel tahminler üzerinde düzeltmeler yapabilir.
- Satış Sahası Tahminleri: Satış temsilcileri, müşteri ile en yakın teması kuran kişiler olduklarından, satış tahminlerinin niteliksel düzeltmelerinde etkin rol oynayabilirler.
- Uzman Oylaması (Polling Expert): Uzun vadeli tahminler için toplantılar pratik olmayabilir; bu nedenle uzman oylaması yöntemi kullanılabilir. Özellikle geçmiş satış verisi olmayan yeni ürünler için uygundur. Bu yaklaşımda uzmanların firma içinden veya dışından olması fark etmez ve genellikle Delphi yöntemi olarak adlandırılır. Delphi yönteminde katılımcılar birbirlerinin yanıtlarını görmeden sorulara cevap verir, yanıtlar özetlenerek tekrar katılımcılarla paylaşılır ve süreç birkaç tur devam ederek en iyi tahmin oluşturulur (Armstrong, 2001).
- Oylama ve Mağazacılık (Polling and Retailing): Bu yöntemde, müşteri ile doğrudan ilişkili satış yöneticilerinin kararları esas alınır. Hangi ürün veya markaların satılacağına ilişkin kararlar bu yaklaşım ile belirlenir ve özellikle geniş marka portföyüne sahip firmalar için kullanışlıdır (Çiçek ve Demir, 2017).

Niteliksel tahminleme teknikleri, uzman yargısına dayalı esnek bir alternatif sunmakta ve karar vericilere kısa vadeli öngörüler sağlamaktadır (Hyndman & Athanasopoulos, 2021). Bununla birlikte, bu tekniklerin öznel değerlendirmelere dayanması, farklı uzmanların ortak görüş sunamaması ve perakende verisinin çok büyük olması sonucu sayısal kesinliği sağlayamaması zayıf yönlerini göstermektedir (Makridakis,

Wheelwright & Hyndman, 1998). Bu nedenle niteliksel teknikler büyük veri yapıları için tamamlayıcı rolü oynasa da, yüksek doğruluk beklenen satış tahminlemede tek başına yeterli olmamaktadır (Hassani et al., 2018). Büyük verilerde, gerçek hayata en yakın doğruluğa ulaştıran makine öğrenmesi gibi modern yöntemlere olan ihtiyaç artmaktadır (Bose & Mahapatra, 2020; Wen et al., 2017).


2.6.3. Hibrit (Niteliksel ve Niceliksel) Yöntemler

Satış tahminlerini etkileyen faktörler, kontrol edilebilir ve kontrol edilemeyen olarak iki gruba ayrılabilir.

- Kontrol Edilebilir Faktörler: Pazar hareketleri ve işletmenin kendi stratejik girişimleri gibi doğrudan yönlendirilebilen unsurları kapsar.
- Kontrol Edilemeyen Faktörler: Direkt ve endirekt etkiler olarak iki alt gruba ayrılır. Direkt etkiler arasında rakip firmaların hareketleri, tedarik zincirine erişim veya yasal düzenlemeler sayılabilir. Endirekt etkiler ise zaman perspektifine göre değişir; kısa ve orta vadede ürün yaşam döngüsü ve hedef pazarın karakteristik özelliklerindeki değişimler, uzun vadede ise ülkenin ekonomik, sosyal, politik ve kültürel koşulları etkili olabilir (Koçel, 2020).

Hibrit yöntemlerde, satış tahminleri hem çevresel hem de kontrol edilemeyen faktörler dikkate alınarak oluşturulur. Ancak bu faktörler araştırılıp ağırlıklandırılrsa dahi, tahminlerin kesin doğruluğu üzerinde her zaman bir belirsizlik bulunabilir.

Hibrit niceliksel ve niteliksel yöntemler değişkenler arası ilişkileri kısmen çözümleyebilse de, büyük veri yapısını işleme, değişkenler arasındaki doğrusal olmayan ilişkileri öğrenme ve modelin performansını en iyi hale getirme noktasında makine öğrenmesi tabanlı tahmin yöntemlerinin gerisinde kalmaktadır (Fry & Steele, 2020).



Şekil 2.1: Satış Tahminini Etkileyecek Faktörlerin Gruplandırılması

2.6.4. Yapay Zeka Destekli Tahminler

Yapay zekâ destekli yöntemler 1990'lı yıllardan itibaren veri analitiğinde kullanıldığı literatürde görülmekte ve doğrusal olmayan ilişkileri modelleme konusunda önemli gelişmelere olanak sağlamıştır (Haykin, 2009). Bu yöntemler, tahmin doğruluğunu artırabilen esnek matematiksel bir yapıya sahiptir. Bu yapı sayesinde geleneksel yöntemlere göre tahminlemede önemli performans üstünlüğü sunmaktadır (Zhang, Patuwo & Hu, 1998). Ancak yapay zekâ yöntemleri geleneksel istatistiki yöntemlere göre daha üstün performans gösterse de her durum için en iyi tahmin sonucuna ulaştıramamaktadır. Veri yapısına, değişken sayısına ve model karmaşıklığına bağlı olarak dezavantajları bulunmaktadır. Bu sebeple genellikle makine öğrenmesi algoritmalarıyla beraber veya tamamlayıcı unsur olarak kullanılmaktadır (Makridakis, Spiliotis & Assimakopoulos, 2020). Tahminleme çalışmalarında sıklıkla kullanılan yapay zekâ yöntemlerine aşağıda yer verilmiştir.

2.6.4.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları (YSA), ilk olarak McCulloch ve Pitts (1943) tarafından yapılan çalışmada sınırlı sayıda ele alınan nöron ve ayarlanabilir sinaptik ağırlıklar işleme alınarak bir model oluşturulmuştur. Bu modelin hesaplanabilir bir fonksiyonda kullanışlı olduğunu göstermişlerdir (Akkaya, 2007). Kendi kendine öğrenme becerisine sahip olan yapay sinir ağları, öğrenme ve ezberleme süreçleri aracılığıyla veriler arasında ilişki kurmaktadır. Yapay sinir ağlarının eğitimi, örnek veri sayısı ne kadar fazlaysa, sorun çözmedeki performansının o kadar başarılı olacağı şekilde gerçekleşmektedir (Deveci ve Ersoy, 2012). Eğitim süreci öncelikle hata değerlerinin

kabul edilmesiyle başlamaktadır. Bu süreçte, eğitimde kullanılan verilerin sınırlı olduğu ve sistemin karmaşık hale geldiği durumlarda ağıın performansında farklılıkların ortaya çıktığı görülmektedir.

Tahmin ve sınıflandırma başarısı yüksek olan YSA öğrenme süreçleriyle yeni bilgiler üretmekte, keşfetmekte ve örnek verilerle eğitilebilmektedir. Yapay sinir ağları katmanlardan oluşmaktadır. Verinin ağı ilk kez girildiği katman giriş katmanı olup burada alınan veri gizli katmanlarda işlenmektedir (Ayyıldız ve diğ., 2021). Bu aşamadaki katmanlar gizli katmanlar olarak adlandırılmakta ve sayıları birden fazla olabilmektedir. Gizli katmanlarda işlenen veri süreç sonunda çıktı katmanından “çıktı” olarak süreci tamamlamaktadır.

Yapay sinir ağlarının temel fonksiyonu makine öğrenmesidir. Alışlagelmiş bilgi işleme süreçlerinden farklı olarak, eksik bilgiye sahip örüntülerde dahi etkin sonuçlar vermektedir. Olaylar üzerinden öğrenme sürecini gerçekleştirip olaylar arasındaki bağlantılarda elde edilen bilgileri hafızasında tutmaktadır. Buradan yola çıkarak tahminleme sürecinde başarılı genellemeler yapabilmektedir (Öztemel, 2012: 29-33). Sadece nümerik bilgilerle çalışan, yani sembolik bilgiler girildiğinde dahi nümerik hale çevrilmesi gerekliliğine dayanan yapay sinir ağlarının tahmin yapmada, sınıflandırmada, verilerin ilişkilendirilmesinde, filtrelenmesinde ve yorumlanmasında oldukça sık kullanıldığı görülmektedir (Kozyrev, 2012: 32).

Öte yandan, yapay sinir ağlarının bazı önemli sınırlılıkları da literatürde yer almaktadır. Aşırı uyum eğilimi, yetersiz veri miktarı, uzun eğitim süreci, modelin mimari yapısı ve katman sayılarındaki deneyimsizlik performansını ciddi bir şekilde düşürebilmektedir. Bunu engellemek için YSA modelleri genellikle Random Forest, XGBoost gibi güçlü makine öğrenmesi algoritmalarıyla birlikte kullanılmakta veya desteklenmektedir (Goodfellow, Bengio & Courville, 2016).

2.6.4.2. Derin Öğrenme (Deep Learning)

Derin öğrenme, yapay sinir ağlarına göre çok katmanlı olarak gelişmiş bir versiyonudur. Görüntü, sinyal ve metin gibi büyük veri türlerinde çok daha iyi performans göstermektedir (LeCun, Bengio & Hinton, 2015). Ancak satış tahmini çalışmalarında da büyük ölçüde kullanılan LSTM ve GRU gibi derin öğrenme modellerinin çok büyük veri gerektirdiği görülmektedir. Bunun sonucunda da

hesaplama maliyeti ve model karmaşıklığı yüksek, veri hacminin fazlalığı nedeniyle de hata olasılığı büyük olmaktadır (Makridakis et al., 2020).

Ayrıca M5 yarışması sonuçlarında da görüldüğü üzere XGBoost, LightGBM gibi makine öğrenmesi metotları, derin öğrenme temelli modellere göre daha iyi performans sergilediğini göstermiştir (Makridakis et al., 2022).

2.6.4.3. Bulanık Mantık (Fuzzy Logic)

Bu yöntem belirsizliğin ve değişkenliğin fazla olduğu durumlarda daha gerçekçi tahminler yapmaya olanak sağlamaktadır (Aksoy, 2008). Deneyime dayalı veya matematiksel olarak doğrudan ifade edilemeyen tüketici davranışındaki belirsizlikler, mevsimsel değişimler gibi değişken verilerin yorumlanmasına önemli katkılar sağlamaktadır.

Ancak bu yöntem veri odaklı öğrenme kapasitesindeki düşüklük, çok değişkenli büyük veri setlerinde kural tabanının bir uzman tarafından manuel oluşturulması gibi etkenler nedeniyle tam performans gösterememektedir. Buna bağlı olarak da modern tahminleme alanında daha çok destekleyici bir bileşen olarak kullanılır (Zadeh, 1996).

2.6.4.4. Hibrit Yapay Zekâ Modelleri

Bu modeldeki yaklaşım, yukarıdaki başlıklarda belirtilen tüm tekniklerin güçlü yönlerini birleştirerek performansı daha yüksek, gerçeğe daha uygun tahmin doğruluğuna ulaşmaktır. Literatürde, talep tahmini çalışmaları göstermiştir ki hibrit yapay zekâ modelleri uygulanan tek bir yapay zekâ yöntemine kıyasla daha düşük hata oranları vermiştir. Değişkenler arasındaki doğrusal olmayan ilişkileri ortaya koyarken daha iyi bir başarı sergilemiştir (Qasem et al., 2019).

2.7. Makine Öğrenmesine Geçiş

Çalışmanın literatür kısmında da değinildiği üzere, alışlagelmiş tahmin yöntemleri tüketicinin birçok davranış sürecini modele dâhil edememektedir. Bu durum yüksek değişkenlik gösteren ürün kategorilerinde tahmin hata oranlarının artışı beraberinde getirmektedir (Kotler & Armstrong, 2020).

Makridakis et al. (2018) tarafından 100.000'den fazla zaman serisi üzerinde yapılan M4 yarışması göstermiştir ki geleneksel yöntemlerin ortalama tahmin doğruluğu (sMAPE ölçütü) %18–28 hata payı içermekte, yani yaklaşık %72–82 doğruluk ortaya koymaktadır. Makine öğrenmesi temelli modeller ise veri setlerinde %10–15 hata payı içererek yaklaşık %85–90 doğruluk performansı göstermiştir. Bu farkın başlıca sebepleri: zaman serilerinin tek değişkenli, makine öğrenmesi yöntemlerinin ise çok değişkenli oluşu, veri büyüdükçe makine öğrenmesi temelli algoritmaların öğrenme kapasitelerinin artışı, ancak buna karşılık istatistikî yöntemlerde ise hata oranının artışı gibi faktörler sayılabilir. Bu nedenle literatürde giderek daha fazla tercih edildiği görülmektedir (Martín et al., 2022).

Geleneksel tahmin yöntemleri bölümü hem niceliksel hem niteliksel metotların hangi alanlarda sınırlı kaldığını ortaya koymuştur. Çok değişkenli ve dinamik perakende yapılarında bu yöntemlerin talepteki değişimleri yeterince açıklayamadığı vurgulanmıştır. Bu sebeple makine öğrenmesinin büyük verileri işleyebilme gücü ve karmaşık ilişkileri gerçek hayata yakın bir şekilde ortaya çıkaran özelliği, daha güçlü bir tahminleme aracı olduğunu göstermektedir. Bu çalışma, Türkiye’de bir süpermarketin farklı konumlardaki şubelerinin üç yıl boyunca kaydedilen satış, promosyon ve ürün grubu verileriyle tahminleme yaparken, makine öğrenmesi yöntemlerinin uygulanabilirliğini ortaya koyarak perakende sektörü için değerli bir katkı sunmaktadır. Bu uygulanabilirliği açıklamak üzere sonraki bölümde makine öğrenmesi yöntemleri ele alınacak ve satış tahminlemesine nasıl katkı sunduğuna değinilecektir.

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ

Veri büyüklüğündeki hızlı artış ile birlikte makine öğrenmesi birçok sektörde stratejik açıdan karar destek mekanizmalarının temel bileşeni hâline gelmiştir. Özellikle perakende sektöründe satış hacimlerinin, tüketici davranışlarının, dönemsel etkilerin ve daha birçok özelliğe bağlı olarak çok boyutlu bir şekilde değişmesi nedeniyle makine öğrenmesi tabanlı algoritmaların çok önemli avantajlar sunduğu görülmektedir (Martín, García & Sánchez, 2022).

Perakende satış verileri: mağaza konumları ve teşhir alanı farklılıkları, promosyon etkileri, stok durumları, dönemsel trendler ve buna bağlı gelişen fiyat dalgalanmaları gibi içerir. Bu kadar karmaşık bir yapıyı geleneksel istatistikî tahmin yöntemleri ile yüksek tahmin doğruluğu sağlayabilmek çoğu zaman mümkün olmamaktadır (Makridakis, Spiliotis & Assimakopoulos, 2020). Bu sebeple işletmeler makine öğrenmesi temelli yöntemlere yönelmekte ve daha yüksek doğruluk sağlayan modelleri tercih etmektedir. Bu bölümde makine öğrenmesi kavramının terminolojisi, temel algoritmaları ve yapılan benzer modelleme örneklerinden bahsedilmektedir. Araştırmanın uygulama bölümünde kullanılacak modellerin kuramsal altyapısı oluşturulmakta ve detaylı olarak anlatılmaktadır.

3.1. Makine Öğrenmesi Nedir

Makine Öğrenmesi kavramını ilk ortaya koyan 1959 yılında IBM araştırmacısı Arthur Samuel, "Bilgisayarın açık bir şekilde programlanmadan bir işi öğrenme yeteneği" şeklinde tanımlamıştır. Gün geçtikçe kullanım alanlarının çeşitliliği artan makine öğrenmesi, finanstan oyun sektörüne, pazarlamadan sağlığa birçok alanda veri toplayarak ve bu verileri işleme süreçlerinde istatistiksel ve matematiksel yöntemleri kullanarak çıkarımlarda bulunmaktadır (Mitchell, 1997).

Verilerin çok fazla büyümesi ve değişkenliğin oldukça artması nedeniyle süreçler daha karmaşık hâle gelmiş; geleneksel olarak kullanılan yöntemlerin yorum yapma kabiliyeti düşerek neredeyse imkânsız hâle gelmiştir (Türkmenoğlu & Tantuğ, 2014).

Yapay zekânın bir alt dalı olan makine öğrenmesi, derin öğrenmenin üzerinde ve daha geniş bir çerçeve sunmaktadır. Makine öğrenmesi, çok sayıda ve yoğun bilgi içeren veri girişlerini analiz ederek, karmaşık veri kümeleri aracılığıyla anlamlı ve kabul edilebilir tahminler yapmaktadır (Géron, 2022).

Bu tahminleri yaparken programlanmış algoritmaları kullanan makine öğrenmesi, insana ait öğrenme kalıplarından esinlenerek geliştirilmiştir. Temelde veri ve deneyimlerden yararlanarak yetkin algoritma ve modeller oluşturmayı hedeflemektedir (Sav, Shinde, & Gaikwad, 2021). Bu süreçte yeni veriler sürekli olarak mevcut veri setine dahil edilmekte ve böylece modeller daha geniş bir veritabanına sahip olmaktadır (Uddin, Khan, Hossain, & Moni, 2019). Oluşturulan tüm modeller, kullanım sıklığı ve işlenen veri miktarı arttıkça modelin performansı da o ölçüde artacaktır. Bunun sonucunda doğru tahmine ulaşma başarısı yükselecektir (SAP, 2021).

Diğer yandan, makine öğrenmesi, bilgisayarların verilerden öğrenme ve deneyimlerinden geliştirme yeteneğine sahip olan bilimsel bir çalışma alanıdır. Bu alan, bilgisayarların belirli görevleri gerçekleştirmek için açık programlama olmadan, veriler üzerinden çıkarımlar yaparak performanslarını iyileştirmeyi hedefler. Makine öğrenmesi algoritmaları, veri setlerindeki yapıları ve kalıpları tanımlayarak gelecekteki verileri tahmin etme yeteneğine sahiptir (Jordan ve Mitchell, 2015).

Makine öğrenmesi yöntemleri genellikle gözetimli, gözetimsiz ve pekiştirmeli öğrenme olmak üzere üç ana kategoriye ayrılır. Gözetimli öğrenmede, model etiketlenmiş verilerle eğitilerek giriş-çıkış ilişkilerini öğrenir. Gözetimsiz öğrenmede ise etiketlenmemiş verilerden yapılar ve ilişkiler keşfedilir. Pekiştirmeli öğrenmede model, çevreyle etkileşim kurarak belirli bir hedefi maksimize etmek için stratejiler geliştirir (Kotsiantis, 2007).

Makine öğrenmesi uygulamaları günümüzde birçok alanda yaygın olarak kullanılmaktadır. Görüntü tanıma, doğal dil işleme, öneri sistemleri, finansal tahminler ve sağlık hizmetleri bu alanlardan bazılarıdır. Özellikle derin öğrenme yöntemlerinin gelişmesiyle birlikte, karmaşık veri yapılarının analizi ve yorumlanması daha da etkin hale gelmiştir (LeCun, Bengio ve Hinton, 2015). Aslında makine öğrenmesi yapay zekânın bir alt alanı olup geleneksel bilgisayar programlarından farklı olarak veri odaklı bir yaklaşım benimser. Klasik programlamada insan, kurallara ve verilere göre

çıktılar oluşturan programlar yazarken, makine öğrenmesinde bilgisayar, örnek verilerden kuralları öğrenerek kendi algoritmalarını geliştirir (Domingos, 2012:78).

Tablo 3.1: Makine Öğrenmesi Temel Kavramları ve Açıklamaları

Kavram	Açıklama	Kullanım Amacı
Veri Kümesi (Dataset)	Algoritmaları eğitmek için kullanılan bağımlı ve bağımsız değişkenlerin tümü	Algoritmayı beslemek ve model oluşturmak
Öznitelikler (Features)	Veri setinin alt kümesi; modelin tahmin için kullandığı gözlemler	Modelin girdilerini temsil eder
Etiket (Label)	Hedef değişkenler; modelin öğrenmesi gereken çıktılar	Tahmin ve sınıflandırma yapmak
Model	Girdiler ile çıktılar arasındaki ilişkileri matematiksel olarak ifade eden yapı	Tahmin ve karar destek sistemi oluşturmak
Eğitim (Training)	Modelin veri örüntülerini öğrenme süreci	Modelin tahmin yeteneğini kazanmasını sağlamak
Hiperparametreler	Modelin yapılandırma ve kontrol ayarları	Performansı ve genelleme yeteneğini optimize etmek
Doğrulama (Validation)	Modelin eğitim sırasında performansının değerlendirilmesi için kullanılan veri	Hiperparametre ayarlarını yapmak
Test (Test Set)	Modelin yeni ve görülmemiş veriler üzerindeki performansını ölçmek için kullanılan veri	Modelin genelleme kabiliyetini ölçmek
Çapraz Doğrulama (Cross-Validation)	Veri kümesini alt parçalara bölerek her parçayı doğrulama seti olarak kullanma yöntemi	Aşırı uyum ve yetersiz öğrenmeyi önlemek
Öznitelik Mühendisliği (Feature Engineering)	Mevcut değişkenlerin dönüştürülmesi, yeni özniteliklerin oluşturulması, gereksiz değişkenlerin çıkarılması	Modelin performansını artırmak ve anlamlı öznitelikler oluşturmak

Kaynak: BTK Akademi, 2022

3.2. Makine Öğrenmesi Terminolojisi

Makine öğrenmesi süreçlerinin etkili ve doğru bir şekilde uygulanabilmesi için temel terminolojinin iyi anlaşılması gerekmektedir. Bu bölümde, süreçlerin işletilmesi ve uygulanması sırasında karşılaşılan bazı temel kavramlar ele alınmıştır. Bu kavramlardan ilki olan veri kümesi (dataset), makine öğrenmesindeki algoritmaları eğiten bağımlı ve bağımsız değişkenlerin tümünü ifade eder (Şahinaslan, Günerkan, & Şahinaslan, 2023). Veri setinin alt kümesi olan öznitelikler (features), algoritmaların model ve tahmin oluşturma sürecinde kullandığı gözlemleri temsil eder (Saygın, 2021). Veri gözlemlerine karşılık gelen hedef değişkenler ise etiket (label) olarak adlandırılır. Bu etiketleri öğrenmek amacıyla makine öğrenmesi algoritmaları, girdiler ile çıktılar arasındaki ilişkileri modelleyen matematiksel yapılar olan modeller üzerinde eğitilmektedir.

Modelin parametrelerinin ayarlanması ve optimize edilmesi, modelin veri seti üzerinde eğitilmesi sürecini ifade eder. Eğitim (training) süreci sonunda model, veri içerisindeki örüntüleri öğrenerek tahmin ve modelleme yapabilecek bir yapıya kavuşur. Eğitim sürecinde modelin yapılandırma ve süreç kontrol aşamalarını yöneten ayarlara hiperparametreler denir. Hiperparametreler, modelin performansını ve genelleme yeteneğini doğrudan etkilediğinden, doğru şekilde belirlenmeleri kritik öneme sahiptir.

Makine öğrenmesi süreçlerinde veriler, modelin performansını değerlendirmek ve genelleme yeteneğini artırmak amacıyla farklı alt kümelere ayrılır. Veri kümesinin bir bölümü eğitim (training), bir bölümü doğrulama (validation) ve bir bölümü ise test amacıyla kullanılmaktadır. Doğrulama verisi, modelin hiperparametrelerinin ayarlanması ve eğitim sürecindeki başarısının değerlendirilmesi için kullanılırken, test verisi modelin yeni veriler üzerindeki performansını ölçmek için kullanılır.

Modelin genelleme kabiliyetini güçlendirmek için sıklıkla çapraz doğrulama (cross-validation) yöntemi uygulanır. Bu yöntemde veri kümesi, eşit büyüklükte alt parçalara (k-folds) ayrılır ve her bir parça sırasıyla doğrulama seti olarak kullanılır; kalan parçalar ise eğitim seti olarak değerlendirilir. Böylece modelin başarısı gözlemlenebilir ve aşırı uyum (overfitting) veya yetersiz öğrenme (underfitting) gibi sorunların önüne geçilebilir. Bu süreçlere ek olarak, modelin performansını artırmak amacıyla öznitelik mühendisliği (feature engineering) uygulanır. Öznitelik

mühendisliği, mevcut değişkenlerin dönüştürülmesi, yeni özneliklerin oluşturulması ve gereksiz değişkenlerin çıkarılması gibi işlemleri kapsar (Bilgi Teknolojileri ve İletişim Kurumu [BTK], 2022).

Yetersiz uyum (underfitting), modelin veriyi yeterince öğrenememesi durumunda ortaya çıkar ve eğitim verisi ile test verisinin düşük performans sergilemesine sebep olmaktadır. Bu nedenle model çok basit kalarak, desenleri yakalayamaz ve eğitim ile test hatası yüksek olduğundan genelleme yapamaz hale gelmektedir. Bunun en önemli sebepleri: karmaşık bir ilişkiyi basit bir algoritmayla modellemeye çalışılması, çok az veri ile modelin eğitilmesi ve yetersiz özellik kullanımı olarak görülmektedir (Öztürk, 2021:112-128).

Aşırı uyum (overfitting) ise, makine öğrenme modelinin eğitim verisine fazla uyum sağlayarak çok iyi öğrenmesi sonucu genelleme yapamaması durumu olarak tanımlanabilmektedir. Aşırı uyum sebebiyle eğitim hatası düşük olduğu halde, test verilerinde performansı başarısız olmaktadır. Ayrıca eğitim verisine karşı gösterdiği aşırı uyum, modelin ezberleme yapmasına sebebiyet vererek öğrenme durumunu engellemektedir. Modelin çok karmaşık olup eğitim verisinin az, parametre sayısının ise fazla olduğu durumlarda overfitting çok görülmektedir. Ayrıca gereksiz özelliklerin (feature) modele eklenmesi ve gereğinden çok eğitimin gerçekleşmesi durumlarında da model aşırı uyum sergilemektedir (Yıldırım, 2022: 215-234).

3.3. Makine Öğrenmesi Türleri

2015-2020 yılları arasında E. Tosunoğlu ve ark. Tarafından belirtilen bilgiye istinaden makine öğrenmesi konusuyla ilgili 201 makale yazılmıştır. Bu makalelerin %35,3'ü lisans öğrencilerine aittir. Genellikle çalışmalarda karar ağaçları (%22,5), destek vektör makineleri (%17,8) ve Naive Bayes (%14,2) gibi sınıflandırma yöntemlerinin kullanıldığı görülmektedir (Bakan & Kanbay, 2024).

3.3.1. Gözetimli Öğrenme (Sınıflandırma ve Regresyon)

Makine öğrenmesinde en çok kullanılan yöntemdir. Bazı kaynaklarda denetimli öğrenme olarak geçmektedir. Etiketlenmiş verileri kullanarak bir fonksiyon oluşturmayı amaçlamaktadır (Nizam ve Akın, 2014). Bu etiketli verilerin büyük kısmı

eğitim sürecinde kullanılmaktadır. Geriye kalan veriler ise test amaçlı kullanılmaktadır (Metlek ve Kayaalp, 2020).

Sınıflandırma ve regresyon yöntemleri olarak ikiye ayrılır (Çoban, 2016). Sınıflandırma, çıktıları kategorik olarak verilere ayırır ve algoritmanın verilerin örüntülerini tanıması beklenmektedir (Bozinovski, 1981). Regresyon ise sayısal değerleri olan tahminler bulmak amacıyla kullanılır. Değişkenler arası ilişki kurmaya yönelik modellemeler yapmaktadır (Amasyalı, 2008). Bu bağlamda, sınıflandırma gözetimli öğrenmenin en yaygın uygulamalarından biridir ve belirli giriş verilerini önceden tanımlanmış kategorilere atama işlemidir. Bu yöntemde, model etiketlenmiş eğitim verilerinden öğrenir ve daha sonra yeni etiketlenmemiş verileri sınıflandırmak için bu bilgiyi kullanır. Sınıflandırma algoritmaları, eğitim verileri üzerinde çalışarak giriş özellikleri ile çıktı sınıfları arasındaki ilişkileri tanımaya çalışır (Kotsiantis, 2007).

Sınıflandırma algoritmaları ikili ve çok sınıflı problemleri çözebilir. İkili sınıflandırmada veri noktaları sadece iki kategoriden birine atanırken, çok sınıflı sınıflandırmada birden fazla kategori söz konusudur. Örneğin, bir e-posta filtreleme sistemi "spam" veya "spam değil" şeklinde ikili sınıflandırma yaparken, bir görüntü tanıma sistemi nesneleri birçok farklı kategoriye ayırabilir (Sokolova ve Lapalme, 2009).

Sınıflandırma algoritmalarının performansı genellikle doğruluk, kesinlik, duyarlılık ve F1 skoru (kesinlik ve duyarlılık arasında denge kuran bir ölçüm) gibi metriklerle değerlendirilir. Bu metrikler, modelin doğru ve yanlış tahminlerinin oranlarını farklı açılardan ölçer. Algoritmanın başarısı, karmaşıklık matrisi kullanılarak daha ayrıntılı bir şekilde analiz edilebilir (Fawcett, 2006). Bunlara ilaveten, yaygın sınıflandırma algoritmaları arasında karar ağaçları, lojistik regresyon, destek vektör makineleri, Naive Bayes ve yapay sinir ağları bulunmaktadır. Her algoritmanın kendine özgü avantajları ve dezavantajları vardır ve problem tipine göre uygun algoritma seçimi önemlidir (Fernández et al., 2018: 259).

3.3.1.1. K-En Yakın Komşu

K-En Yakın Komşu (K-Nearest Neighbors, KNN) algoritmaları veri özelliklerini inceleyerek hangi sınıfa ait olduklarını tespit etmeyi amaçlar. Eğitilmiş veri seti ile

çalışmakta olup, test veri seti ile başarısı ölçülmektedir. Bu mantıkla çalışan K-En Yakın Komşu algoritmaları yeni bir veri seti ile karşılaştığında, örnek olarak seçilen bir veri ile K tane komşu verilerin mesafeleri ölçülüp, bu sonuçlara göre karşılaştırmalar yapmaktadır (Taşcı ve Onan, 2016). Eğitim aşamaları şu şekildedir:

- Öncelikle bir K parametresi seçilir. Bu parametre seçilmiş olan veriye en yakın komşu noktalarını göstermektedir. Bu nedenle bu seçilen K parametresinin değeri, komşuları arasındaki uzaklığı ve sınıflandırma problemindeki performansını direkt etkilemektedir.
- Örnek olarak seçilen veri setine yeni bir veri katıldığında, eldeki verilere göre uzaklıklar tek tek fonksiyonlar aracılığıyla hesaplanmaktadır (Metlek ve Kayaalp, 2020).

KNN’de görüldüğü üzere, yeni bir verinin mevcuttakilerle aynı sınıfa ait olduğunda, benzer oldukları kanısına ulaşılmıştır. K En Yakın Komşu algoritması, küçük veri kümelerinde hızlı ve yeterli yanıt verirken, veri kümesi büyüdüğünde verimi düşmektedir (Ujkani, Minkovska, & Stoyanova, 2021). KNN algoritmasının önemli bir avantajı, herhangi bir öğrenme sürecine ihtiyaç duymaması ve doğrudan eğitim verileri üzerinden tahmin yapabilmesidir. Algoritmanın performansı, K değerinin seçimi, uzaklık ölçüsü ve veri normalleştirme gibi faktörlere bağlıdır. Küçük K değerleri daha esnek sınır modelleri oluştururken, büyük K değerleri daha düzgün sınırlar oluşturur (Guo et al., 2003).

KNN yöntemi hesaplama açısından yoğun olabilir, özellikle büyük veri setlerinde, çünkü her tahmin için tüm eğitim örnekleriyle karşılaştırma gerektirir. Bu nedenle, veri boyutu arttıkça algoritmanın verimliliği düşebilir. Bu sorunu çözmek için kd-ağaç veya ball-ağaç gibi veri yapıları kullanılarak hesaplama süresi optimize edilebilir (Peterson, 2009).

3.3.1.2. Karar Ağaçları

Karar ağaçları, adlarından da anlaşılacağı üzere ağaç şeklinde bir modeldir. Akış diyagramlarına benzeyen hiyerarşik bir yapısı bulunmaktadır. Kök düğümlerden, ara düğümlerden, yaprak ve dallardan oluşmaktadır. Sayısal ve kategorik verileri

modelleyebilen, anlaşılması kolay ve yorumlanması basit olan bir algoritmadır. Karar ağacı algoritmasının işlevi, birbirine benzer grupları küçük küçük alt kümelere bölmektir. Bu işlem performansın en uygun olduğu yere kadar devam eder. Buradaki risk çok az sayıda karar ağacı oluşumunda düşük performans sergilenmesi veya çok fazla sayıda karar ağacı oluşumunda ise aşırı öğrenme (overfitting) yaşanıp sapmaların gerçekleşmesi olacaktır. Bu riskin önlenmesi için yeterli sayıda ağaca ulaşılması gerekmektedir. Performans ve hesaplama süresini düşüren optimize değere ulaşmak önemli olmaktadır (Mitchell, 1997).

Karar ağaçlarının bölünme kriterleri genellikle bilgi kazancı, Gini indeksi veya entropi gibi metrikler kullanılarak belirlenir. Bilgi kazancı, bir özelliğin veri kümesini ne kadar iyi ayırabildiğini ölçer. Bölünme öncesi ve sonrası entropi değerleri arasındaki fark olarak hesaplanır. Bilgi kazancı ne kadar yüksekse, o özelliğin sınıflandırma için o kadar değerli olduğu anlaşılır. Yüksek bilgi kazancına sahip özellikler, karar ağacının üst seviyelerinde tercih edilir. Gini indeksi bir veri kümesindeki saflığı ölçer. Değeri 0 ile 1 arasında değişir; 0 değeri tam homojenliği (tüm örnekler aynı sınıfa ait), 1 değeri ise tam heterojenliği gösterir. Karar ağacı algoritması, Gini indeksini minimize eden bölünmeyi seçmeye çalışır. Entropi, bir veri kümesindeki düzensizliği veya belirsizliği ölçer. Yüksek entropi değeri, veri kümesindeki sınıfların eşit dağıldığını gösterir; düşük entropi ise verilerin belirli sınıflarda yoğunlaştığını gösterir. Entropi değeri 0 olduğunda, tüm örnekler aynı sınıfa aittir (Breiman, 2001: 5).

Karar ağaçları kolay yorumlanabilir olmalarından dolayı birçok alanda tercih edilir. Ayrıca, veri ön işleme gereksinimlerinin az olması ve kategorik veriler ile sayısal verileri birlikte kullanabilmesi önemli avantajlarından. Bununla birlikte, aşırı öğrenme problemiyle karşılaşabilirler ve bu sorun budama teknikleriyle azaltılabilir (Quinlan, 1986).

3.3.1.3. Rastgele Orman

Karar ağacı modelleri tarafından oluşturulan çıktıların ve bu ağaç topluluklarının rastgele özellik seçme yöntemiyle birleştirilmesi sonucu rastgele orman algoritması oluşmaktadır (Lantz, 2013). Oluşan bu karar ağaçlarıyla çalışmak yüksek boyutlu bir

öğrenme metodu olup her bir karar ağacının tahmin değerlerini oylayarak en yüksek oyu alanın tercih edilmesine olanak sağlamaktadır (Breiman, 2001).

Tek bir karar ağacında çıkan tahmin sonucuna göre çok değişkenli olan bir ağaç topluluğunun eğitilmesi, büyük ve dengesiz veri kümesinde hatayı dengeli halde tutmaktadır. Hatta kaybolan veriler olduğunda dahi tahmine yönelik doğruluk korunur (Şahin, 2016). Çok sayıda çalışma rastgele orman algoritmalarının en doğru sonucu veren öğrenme teknikleri arasında saymaktadır. Uygulama yöntemi hızlı ve kolay olup doğruluğu yüksek tahminler üretmektedir. En avantajlı yönlerinden biri ise aşırı uyuma maruz kalmadan çok sayıda girdiği sorunsuz işleyebilir (Ujkani, Minkovska, & Stoyanova, 2021).

Rastgele Orman algoritmasının bir başka önemli avantajı ise bireysel ağaçların tahminlerini birleştirerek (genellikle sınıflandırma problemlerinde çoğunluk oylaması, regresyon problemlerinde ortalama alma yoluyla) daha kararlı ve doğru sonuçlar üretmesidir. Bu yaklaşım, varyansı azaltarak modelin genelleme kabiliyetini artırır ve aşırı öğrenme riskini düşürür (Liaw ve Wiener, 2002).

Algoritma, özellik önem derecelerini hesaplayabilme yeteneği ile değişkenlerin modele katkısını değerlendirmeye olanak tanır. Bu özellik, kullanıcılara hangi girdilerin tahmin sürecinde daha etkili olduğunu anlama imkânı sağlar (Genuer et al., 2010).

3.3.1.4. Lojistik Regresyon

Lojistik regresyon, bağımsız değişkenler hakkında bir varsayımda bulunmayan $-\infty$ ile $+\infty$ arasındaki bütün değerleri girdi olarak değerlendiren ve bağımlı değişkenin iki kategorili olduğu durumlarda 0 ya da 1 olarak çıktıyı oluşturan denetimli bir makine öğrenmesi türü olarak tanımlanmaktadır (Singh et al., 2016). İkili sınıflandırma problemlerinde çok etkili olan lojistik regresyon, içinde barındırdığı fonksiyon ile örneklemelerin sınıflarını belirlemektedir (Tekin, 2024).

Doğrusal regresyon analizinde birçok olasılık gözlemlenirken, lojistik regresyonda ise bu görülmemektedir (Şenel ve Alatl, 2014: 36). Sınıflandırma amaçlandığından, bağımlı ve bağımsız değişkenler araştırılmakta ve buna göre atama yapılmaktadır. Bağımlı değişkenin sürekliliği ve bağımsız değişkenlerin çoklu normal dağılımı beklenmediğinden risk olasılıkları da dahil edilmektedir (Ege ve Bayrakdaroglu, 2009:

147). Bu özellik diğer regresyon türlerinden lojistik regresyon türünü ayırmaktadır (Girginer ve Cankuş, 2008: 185). Ayrıca varyans-kovaryans matrislerinde bire bir aramanın da bir diğer farklardan biridir.

Lojistik regresyon 3 farklı model ile çalışmaktadır (Şenel ve Alatl, 2014: 36):

- İkili (Binary): Bu lojistik regresyon modeli bağımlı değişkenin ikili olduğu durumlarda kullanılmaktadır (Evet/Hayır gibi).
- Multinomial: Bağımlı değişkenin çok seçenekli olduğu durumlarda kullanılmaktadır.
- Sıralı (Ordinal): Birden fazla farklı kategoride yer alan sıralı bir durum olarak görülmekte olan bir lojistik regresyon modelidir.

3.3.1.5. Destek Vektör Makinesi

Destek vektör makineleri bir sınıflandırma algoritması olup öncelikle iki sınıflı doğru ayrılabilen verilerde kullanılmaya başlanmıştır. Sonraki zamanlarda ise doğru ayrılamayan verilerin sınıflandırılması ve çok sınıfların ayrılması problemi destek vektör makinelerine uyarlanmıştır (V. Vapnik, 1999; V. N. Vapnik, 1995).

Destek vektör makineleri yönteminin amacı, elde edilecek yeni verinin kategorize edilmesinde destek olacak veri setlerinin sınıflandırılmasını sağlayan bir doğru ya da karar sınırı denilen bir hiperdüzlem oluşturmaktır (Noble, 2006). Bu yöntemin çalışma biçimi sınıfları birbirinden ayıracak biçimde marjlinli hiperdüzlem seçimiyle başlar. Sonrasında verileri sınıflara ayırmada en uygun hiper düzlem seçilir ve destek vektörleri belirlenir (Diler ve Demir, 2024). Bu düzleme en yakın olan ve konumunu belirleyen noktalar destek vektörleri olarak isimlendirilir. Destek vektörleri arasında uzaklık ölçümü yapılır ve iki sınıf arasındaki mesafenin (marjin) en fazla olduğu hiperdüzlem belirlenerek çalışma tamamlanır.

3.3.1.6. Naive Bayes

Sınıflandırma teknikleri arasında kısıtlayıcılığı en fazla olan Naive Bayes yöntemidir. Bayes teoremine dayanan Naive Bayes, verilerin sınıflarını ve bulundukları sınıflara göre olasılıklarını hesaplamaktadır (Solmaz, Günay ve Alkan, 2014: 4). Naive Bayes

algoritması, denetimli öğrenme gerçekleştirirken, olayların gerçekleşme ihtimalini de belirlemeye yardımcı olur (Kazan ve Karakoca, 2019: 19). Veri madenciliği, duygu analizi, tıp vb. gibi çeşitli alanlarda kullanıldığı görülmektedir (Şahinaslan, Dalyan ve Şahinaslan, 2022: 225).

Naive Bayes algoritması geleneksel olarak sınıflandırma için kullanılsa da, regresyon problemlerine de uyarlanabilmektedir. Özellikle Gaussian Naive Bayes modeli, regresyon uygulamalarında özellikle kullanışlıdır çünkü çıktı değişkenini sürekli bir olasılık dağılımı olarak modelleyebilir. Bu uyarlamada, hedef değişkenin koşullu olasılık dağılımı normal dağılım olarak kabul edilir ve algoritma tahmin edilen çıktı değerinin beklenen değerini hesaplar (Frank et al., 2000).

Makine öğrenmesinde regresyon terminolojisi nedensellik ilişkisini ortaya koymaktan öte, gelecek değerlerin tahminlenmesine dayanmaktadır. Bağımlı değişken hedef (target), bağımsız değişken ise özellik (feature) olarak adlandırılır ve regresyon modelinin özelliklerin sayısı ve hedef değişkenin yapı durumuna göre farklı isimler aldığı literatürde görülmektedir.

3.3.1.7. Lineer Regresyon

Regresyon analizi gözlenen bir durumun hangi olayların etkisinde olduğunu araştırır. Bu durum bir veya birden çok olaydan direkt ya da dolaylı olarak etkilenebilmektedir. Gözlem değerlerinin ve etkilenen olayların bir fonksiyon aracılığıyla matematiksel olarak gösterildiği bir model oluşturulması gerekmektedir. Regresyon analizi yapılırken oluşturulan bu model regresyon modeli olarak adlandırılmaktadır. Etkilenen olay olarak bahsedilen ve genellikle konusunu oluşturan olaylara değişkenler denilmektedir. Bağımlı ve bağımsız değişkenler olarak ikiye ayrılmaktadır. Birden fazla bağımsız değişkenin de bulunabileceği regresyon modelinde sebep-sonuç ilişkisi bu değişkenler ile anlatılmaktadır. Bir tane bağımsız değişkenin bulunduğu model basit doğrusal regresyon, birden fazla değişkenin bulunduğu model ise çoklu regresyon olarak tanımlanmaktadır (Atcılı, 2021). İstatistik biliminde değişkenler arası ilişkinin derecesini gösteren katsayıya korelasyon katsayısı, fonksiyonel şeklini oluşturan denkleme ise regresyon denklemi adı verilmektedir.

Makine öğrenmesi ve istatistiksel analizde en temel ve yaygın kullanılan denetimli öğrenme algoritmalarından “Lineer regresyon”dur. Bu yöntem, bağımlı değişken ile

bir veya daha fazla bağımsız değişken arasındaki doğrusal ilişkiyi modellemek için kullanılır. Algoritma, gözlemlenen veri noktalarına en iyi uyan doğrusal denklemi bulmayı amaçlar ve bu denklem genellikle $y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon$ şeklinde ifade edilir. Burada y bağımlı değişkeni, x 'ler bağımsız değişkenleri, β 'lar katsayıları ve ε hata terimini temsil etmektedir (Alin, 2010: 371).

Lineer regresyon modelinin parametreleri, genellikle en küçük kareler yöntemi kullanılarak tahmin edilir. Bu yöntem, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin toplamını (hata kareler toplamı) minimize etmeyi amaçlar. En küçük kareler çözümü analitik olarak hesaplanabilir ve bu, yöntemin hesaplama verimliliğini artıran bir avantajdır (James et al., 2013: 61).

Lineer regresyon modellerinin değerlendirilmesinde genellikle belirlilik katsayısı (R^2), ortalama kare hata (MSE) ve ortalama mutlak hata (MAE) gibi metrikler kullanılır. R^2 değeri, modelin bağımlı değişkendeki varyansı açıklama yeteneğini gösterir ve 0 ile 1 arasında değerler alır; değer 1'e yaklaştıkça model performansı artar (Chatterjee ve Hadi, 2006).

3.3.1.8. Çoklu Lineer Regresyon

Çoklu lineer regresyon birden çok özellik ile tek bir bağımlı değişken arasındaki ilişkiyi modelleyen gözetimli öğrenme algoritmasıdır. Basit lineer regresyonun arasındaki fark, birden fazla bağımsız değişkene sahip olmasıdır. Bağımsız değişkenlerin fazla oluşu karmaşık ilişkiler doğurmaktadır. Bu ilişkinin hangi faktörlerden etkilenip etkilenmediğini belirlemeye yardımcı olmaktadır. Ayrıca bu regresyon analizi sosyal bilimlerde, mühendislik dalları, ekonomi ve farklı disiplinlerde verilerin analizi, tahmini ve modellemesinde kullanılmaktadır (Farrar ve Glauber, 1967).

Çoklu lineer regresyon modelinde, n sayıda bağımsız değişken olduğunu varsayalım. Burada Y bağımlı değişkeni, $X_1, X_2, \dots, X_n$ ise bağımsız değişkenleri göstermektedir. $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ ise bilinmeyen parametreleri, ε ise hata terimini ifade etmektedir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon$$

Bu regresyon modelinde birtakım varsayımlar kabul edilmektedir. Hata terimi (ϵ) ile bağımsız değişkenler arasındaki ilişki ve dağılım ile ilgili olan bu varsayımların doğru ve güvenilir tahminlerin yapılması için önemli olduğu görülmektedir. Doğru sonuçlara ulaşılabilmesi için hata terimleri sabit bir varyansa sahip olmalı, aralarında ilişki bulunmamalı (otokorelasyon), ortalamaları sıfır ve normal bir dağılım izlemelidir. Ayrıca bağımsız değişkenlerde çoklu bağlantı bulunmamalıdır. Yani, bağımsız değişkenler aralarında güçlü bir ilişkiye sahip olmamalıdır. Bu şekilde mümkün görülmektedir (Helland, 2001).

3.3.1.9. XGBoost (Extreme Gradient Boosting)

XGBoost (Extreme Gradient Boosting), karar ağacı tabanlı gradyan artırma algoritmalarının geliştirilmiş bir türüdür. Son yıllarda makine öğrenmesi alanında sıkça kullanılan bu yöntem, tahmin performansı, hızlı eğitim süresi ve büyük veri setleriyle uyumlu çalışması nedeniyle yaygın olarak tercih edilmektedir. XGBoost, Friedman (2001) tarafından geliştirilen Gradient Boosting yaklaşımını temel almaktadır. Bu algoritmanın en önemli avantajlarından biri, modelleme sürecinde eksik verilerle etkili bir şekilde çalışabilmesidir. Ayrıca algoritmanın paralel işlem yapısı avantajıyla hesaplamaları tek tek gerçekleştirmek yerine aynı anda birden fazla işlem üzerinden yapabilmektedir (Chen & Guestrin, 2016). Bu sayede büyük veri setleri ile çalışırken eğitim süresini önemli ölçüde azaltmaktadır.

Çalışmalarda XGBoost algoritmasının perakende satış tahmini, enerji talebi tahmini ve finansal risk modelleme gibi birçok farklı alanda yüksek tahmin doğruluğu ile başarılı sonuçlar verdiği görülmektedir (Bentéjac, Csörgő & Martínez-Muñoz, 2021). Ayrıca veri bilimi yarışmalarında da sıklıkla kullanılan bir yöntem olması, XGBoost'un uygulamalardaki başarısını ortaya koymaktadır (Zheng, 2017).

Bununla birlikte XGBoost algoritmasının bazı sınırlılıkları da bulunmaktadır. Modelde kullanılan ağaç sayısı, öğrenme oranı ve ağaç derinliği gibi çok sayıda hiperparametrenin bulunması, model performansını doğrudan etkileyebilmektedir (Chen & Guestrin, 2016). Bu hiperparametrelerin dikkatli şekilde optimize edilmesi gerekmektedir. Ayrıca karar ağacı tabanlı bir yöntem olması nedeniyle model çıktılarının yorumlanabilirliği bazı durumlarda sınırlı olabilmektedir.

3.3.1.10. LightGBM (Light Gradient Boosting Machine)

LightGBM (Light Gradient Boosting Machine), Microsoft Research tarafından geliştirilen ve gradient boosting karar ağacı tabanlı bir makine öğrenmesi algoritmasıdır. LightGBM, özellikle büyük veri setleri üzerinde hızlı çalışabilmesi nedeniyle son yıllarda makine öğrenmesi çalışmalarında sıkça kullanılmaktadır. Diğer önemli avantajları ise modelin eğitilmesi sürecinde düşük bellek kullanımı ile özellikle çok sayıda gözlem içeren büyük hacimli veri setlerinde modelin daha verimli şekilde eğitilmesine imkân sağlaması ve yüksek işlem hızı bu modeli oldukça öne çıkarmaktadır (Ke et al., 2017).

Ayrıca LightGBM, boosting algoritmalarından farklı olarak geleneksel karar ağaçlarındaki gibi seviyeye göre dengeli bir büyüme stratejisini kullanmayıp modelde hata payını azaltmaya en fazla katkı sağlayan dallar öncelikli olarak genişletilmektedir. Böylece, modelin özellikle büyük veri setlerindeki öğrenme hızı ve tahmin performansını artırmaktadır (Chen & Guestrin, 2016; Bentéjac et al., 2021). Tüm bu hızlı eğitim süresi, çalışma hızı ve yüksek doğruluk oranı gibi avantajlar, bu algoritmanın gerçek hayat uygulamalarında ve literatürde bahsi geçen veri bilimi yarışmalarında sıklıkla tercih edilme sebebini göstermektedir.

Öte yandan LightGBM algoritmasının bazı sınırlılıkları da bulunmaktadır. Histogram tabanlı öğrenme yaklaşımı, bazı durumlarda veri üzerindeki çok hassas eşik değerlerini tam olarak ayırt etmekte zorlanabilmektedir. Bu durum da model performansını sınırlayabilir. Bununla birlikte, küçük ölçekli veri setlerinde modelin sağladığı hız ve doğruluk avantajlarının daha sınırlı kaldığı ve hiperparametre ayarlarının dikkatli yapılması gerektiği literatürde belirtilmektedir (Ke et al., 2017).

3.3.2. Gözetimsiz Öğrenme

Gözetimli öğrenme hangi veriler arasında ilişki kurulacağı kararını kullanıcıya bırakırken, gözetimsiz öğrenme de ise seçim algoritmaya bırakılmaktadır (Jordan & Mitchell, 2015). Denetimsiz öğrenme yaklaşımında etiketsiz verilerle çalışılmaktadır. Bu algortmada mevcuttaki veriler arasında ilişkiler keşfedilerek sınıflandırma yapılmaktadır. Bu yaklaşımın temeli Hebbian öğrenme kuralındaki mantığa dayanmaktadır (Keskenler, 2017).

Hebbian öğrenme kuralına göre birbiriyle ilişkili olan nöronlardan ikisi de aktifse ilişki artmakta, diğer durumda ilişki azalmaktadır. Sosyal mecralarda video, arkadaş ya da sayfa önermeleri ve bunların dışında yapılmak istenen tüm gruplandırma işlevlerinde gözetimsiz öğrenme algoritmaları kullanılmaktadır (Demir, 2023: 178-195).

Bu bağlamda, gözetimsiz öğrenme, veri bilimi ve makine öğrenmesi alanlarında etiketlenmemiş verilerden gizli yapıları keşfetmeyi amaçlayan bir yaklaşımdır. Gözetimli öğrenmeden farklı olarak, algoritmanın eğitimi sırasında hedef değişken veya çıktı değeri bulunmamaktadır. Bu nedenle sistem, veriler arasındaki içsel ilişkileri, benzerlik desenlerini ve yapıları kendi başına keşfetmeye çalışır (Hastie et al., 2009: 485).

Gözetimsiz öğrenme algoritmaları temel olarak iki kategoriye ayrılmaktadır: kümeleme ve boyut indirgeme. Kümeleme algoritmaları, benzer özelliklere sahip veri noktalarını gruplandırmayı amaçlar. Bu algoritmalar müşteri segmentasyonu, görüntü sıkıştırma ve anomali tespiti gibi çeşitli uygulamalarda kullanılmaktadır (Jain, 2010).

Boyut indirgeme algoritmaları ise yüksek boyutlu veri setlerini daha düşük boyutlu bir uzaya dönüştürerek verinin daha kolay yorumlanabilmesini ve görselleştirilmesini sağlar. Bu algoritmalar, veri setindeki gürültüyü azaltmak, veri görselleştirmesi yapmak ve hesaplama verimliliğini artırmak için kullanılmaktadır (Van der Maaten ve Hinton, 2008).

Bunlara ilaveten, gözetimsiz öğrenme, keşifsel veri analizinin önemli bir parçasıdır ve genellikle daha karmaşık makine öğrenmesi iş akışlarının bir ön adımı olarak kullanılır. Bununla birlikte, bu algoritmaların başarısı, kullanılan benzerlik ölçütlerine, veri kalitesine ve problem alanına bağlı olarak değişebilir. Algoritmalar, verinin doğasına uygun parametrelerle yapılandırılmalı ve sonuçlar domaine özgü bilgilerle değerlendirilmelidir (Xu ve Wunsch, 2005: 647).

3.3.2.1. Kümeleme (Clustering)

Bir veri seti içerisinde farklı grupların bulunup bulunmadığını belirlemek ve varsa bu grupları tespit etmek amacıyla kullanılan çok değişkenli bir yöntemdir. Bu istatistiksel yöntem, çok boyutlu uzayda verileri özetleme ve tanımlama yapmada yol gösterici olmaktadır (Tatlıdil, 2002). Gruplama yapmayı sağlayan kümeleme analizi, farklı

gruplardaki heterojen gözlem yapılarını veya homojen olan benzer gözlem yapılarını çok boyutlu uzayda özetlemekte ve tanımlamaktadır (Çelik ve ark., 2004). Kümeleme yöntemi ile belirlenen kriterler göz önüne alınarak, gözlemlerin gruplandırılma süreci ile veriler azaltılabilmekte ya da özet bilgiler içeren üst gruplar oluşturulabilmektedir (Kalaycı ve ark., 2005).

Kümeleme, gözetimsiz öğrenme yöntemlerinden biri olup etiketlenmemiş veri noktalarını benzerliklerine göre gruplandırma işlemidir. Bu teknik, veriler arasındaki doğal grupları keşfetmeyi amaçlar ve her küme içindeki nesnelerin birbirine benzer, farklı kümelerdeki nesnelerin ise birbirinden mümkün olduğunca farklı olmasını hedefler (Jain, 2010: 652).

Kümeleme algoritmaları genellikle hiyerarşik ve bölümleyici olmak üzere iki ana kategoriye ayrılır. Hiyerarşik kümeleme, verileri ardışık bir şekilde birleştiren veya bölen bir ağaç yapısı oluşturur. Bölümleyici kümeleme ise verileri önceden belirlenmiş sayıda kümeye ayırır. K-means, en yaygın kullanılan bölümleyici kümeleme algoritmasıdır ve hesaplama verimliliği nedeniyle büyük veri setlerinde tercih edilir (Celebi vd., 2013).

Kümeleme, müşteri segmentasyonu, anomali tespiti, görüntü sıkıştırma ve biyoinformatik gibi çeşitli alanlarda uygulanmaktadır. Ancak küme sayısının belirlenmesi, uygun benzerlik ölçütünün seçilmesi ve farklı ölçeklerdeki özelliklerin ele alınması gibi zorluklar da bulunmaktadır (Rodriguez ve Laio, 2014).

3.3.2.2. Boyut İndirgeme (Dimensionality Reduction)

Bir verinin anlamını yitirmeyecek şekilde yüksek boyutlu uzaydan daha düşük boyutlu uzaya dönüştürülmesine boyut indirgeme denilmektedir (Yıldız ve Sevim, 2020). Boyutu fazla olan bir veri setini işlemek işlem yükünü ağırlaştırdığından, boyut indirgemesi sıkça kullanılmaktadır (Van Der Maaten, Postma, & Van Den Herik, 2009).

Bu yaklaşım doğrusal ve doğrusal olmayan şeklinde ikiye ayrılmaktadır (Van Der Maaten, Postma, & Van Den Herik, 2009). Mevcutta bulunan değişkenlerin bir alt kümesini seçerek veya yeni değişkenler oluşturularak yapılabilir (Pudil & Novovičová, 1998). Gürültü filtreleme, kümeleme veya verilerin görselleştirilmesi

amacıyla kullanıldığı gibi başka makine öğrenmesi türlerinin ön adımı olarak da uygulanabildiği görülmektedir.

Boyut indirgeme, yüksek boyutlu veri setlerindeki değişken sayısını azaltarak veriyi daha düşük boyutlu bir uzayda temsil etmeyi amaçlayan bir tekniktir. Bu yöntemler, veri görselleştirme, hesaplama karmaşıklığını azaltma ve yüksek boyutluluğun lanetinden kaçınma gibi amaçlarla kullanılmaktadır (Cunningham ve Ghahramani, 2015: 513).

Temel Bileşen Analizi (PCA), en yaygın kullanılan doğrusal boyut indirgeme yöntemidir ve veri setindeki varyansı maksimize eden yeni ortogonal eksenler oluşturur. PCA, veri analizinin ilk aşamalarında keşifsel bir araç olarak sıklıkla kullanılmaktadır. Doğrusal olmayan boyut indirgeme teknikleri arasında yer alan t-SNE (t-Distributed Stochastic Neighbor Embedding) ise özellikle yüksek boyutlu verilerin iki veya üç boyutlu görselleştirmelerinde etkileyici sonuçlar üretmektedir (Shlens, 2014).

Boyut indirgeme teknikleri, görüntü işleme, biyoinformatik, metin madenciliği ve diğer birçok alanda önemli rol oynamaktadır. Ancak bu tekniklerin kullanımında, bilgi kaybı ve yorumlanabilirlik arasında bir denge kurmak gerekmektedir (Van der Maaten ve Hinton, 2008: 2580).

3.3.2.3. Bağıntı Kurma

Veri madenciliğinde kullanılan bağıntı kurma yöntemi, büyük veri kümelerinde öğeler ile ilgili ilişkileri ortaya çıkarmayı amaçlamaktadır (Zaki, 2000). Marketteki satın alma olaylarının analizinde, yani müşterilerin hazırladığı alışveriş sepetlerinde, hangi ürünü hangi ürünle aldığı konusunda işletmeciler için ürün yerleştirme, kampanya dönemlerini belirleme ve öneri bilgi sistemlerini hayata geçirme hususlarında stratejik kararlar almalarına olanak sağlamaktadır.

Bu yaklaşımda en çok kullanılan algoritmalar Apriori ve Eclat yöntemleridir. Apriori algoritması veri setindeki sık kullanılan öğe gruplarını tespit etmek ve bunlardan anlamlı ilişkiler ortaya çıkarmak amacıyla ortaya konulmuştur (Tan, Steinbach & Kumar, 2019).

Market sepet analizlerinde oldukça sık kullanılmaktadır. Eclat algoritması da Apriori algoritması gibidir. Yani, sık öge gruplarını bulmayı amaçlamaktadır. Farklı olarak veri setini dikey olarak temsil etmekte ve bu şekilde daha hızlı işlem gerçekleştirmektedir (Han, Pei & Kamber, 2011).

Bağıntı kurma, büyük veri setlerinde sıklıkla birlikte görülen öğeler arasındaki ilişkileri keşfetmeyi amaçlayan veri madenciliği tekniğidir. Bu yöntem, özellikle sepet analizi olarak da bilinen perakende sektöründeki müşteri satın alma davranışlarını anlamak için yaygın olarak kullanılmaktadır. Bağıntı kuralları, "Eğer X ürünü alınmışsa, Y ürünü de alınacaktır" formunda ifade edilebilir ve bu kurallar destek, güven ve kaldıraç gibi metriklere göre değerlendirilir (Agrawal et al., 1993).

Bağıntı kurallarını çıkarmak için en yaygın kullanılan algoritma Apriori algoritmasıdır. Bu algoritma, minimum destek eşiğini karşılayan sık öge kümelerini belirlemek için aşağıdan yukarıya bir yaklaşım kullanır. Sık öge kümelerinin tanımlanmasının ardından, minimum güven eşiğini sağlayan kurallar oluşturulur. Apriori algoritması, büyük veri setleri için hesaplama açısından yoğun olabilmektedir (Hahsler et al., 2005).

FP-Growth (Frequent Pattern Growth) algoritması, Apriori'nin alternatifi olarak geliştirilmiş olup, veri yapısı olarak FP-Tree (Frequent Pattern Tree) kullanır. Bu algoritma, daha az bellek kullanımı ve daha yüksek işlem hızı sunarak büyük veri setlerinde daha verimli çalışmaktadır (Han vd., 2000).

Bağıntı kurma yöntemleri perakende sektörü dışında da çeşitli alanlarda uygulanmaktadır. Örneğin, web sayfası tıklama analizleri, gen ifadesi analizi, tıbbi tanı ve dolandırıcılık tespiti gibi alanlarda kullanılmaktadır. Ancak düşük destek ve yüksek güven değerlerine sahip çok sayıda kural üretilmesi, yorumlama ve değerlendirme zorluklarına neden olabilmektedir (Agrawal et al., 1993).

Tablo 3.2: Yapılan Benzer Çalışmalar

Çalışmanın Adı	Yazar	Çalışma Alanı	Kurulan İlişki	Kullanılan Ölçekler	Bulgular
Makine Öğrenmesi Algoritmaları ile Satış Tahmini	Emine Nur Nacar Babek Erdebilli (2021)	Genel satış/talep tahmini; çeşitli sektör verileri üzerinde uygulama	Zaman serisi / regresyon temelli satış verisi üzerine ML modellerinin (Doğrusal Reg., Ridge, Lasso, ElasticNet, KNN, Random Forest) performans karşılaştırması	MSE, MAE, RMSE, MAPE gibi hata metrikleri	Uygulamada en düşük hata veren model Random Forest olarak raporlanmış; ML yöntemleri geleneksel yaklaşımlara göre daha iyi performans sergilemiş.
Perakende Sektöründe Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Performans Analizi (Black Friday Satış Tahminlemesi)	Vahid Sinap (2024)	Büyük perakende / mağaza tabanlı satış tahmini (perakende zinciri verileri)	Farklı ML algoritmalarının (ensemble ve tekli modeller) mağaza/ürün bazlı satış tahminindeki göreceli performansları karşılaştırılmış	MAE, RMSE, MAPE; ayrıca model karşılaştırma metrikleri	Ensemble yaklaşımlar ve ağaç tabanlı modeller (örn. Random Forest, Gradient Boosting) yüksek performans göstermiş; mağaza bazlı farklılıkların modele etkisi vurgulanmış.
Makine Öğrenmesi ve Derin Öğrenme Yöntemleri Kullanılarak e-Perakende Sektörüne Yönelik Talep Tahmini	Mehmet Acı Gamze Ayyıldız Doğansoy (2022)	e-perakende (online perakende) talep/satış tahmini	Geleneksel ML ve derin öğrenme modellerinin (ör. XGBoost, LSTM benzeri) e-perakende verisiyle karşılaştırılması; farklı özellik mühendisliği yaklaşımları incelenmiş	RMSE, MAE, MAPE, R ²	Derin öğrenme ve belirli ML modelleri (özellikle zaman serisi için LSTM/benzeri) belirli ürün kategorilerinde iyi sonuçlar vermiş; özellik mühendisliği ve dışsal ekonomik değişkenlerin (TÜFE vb.) eklenmesi tahmin doğruluğunu artırmış.
Makine Öğrenmesi ile Talep Tahmini ve Envanter Yönetimi	Amine Bayar Serbest (2024)	Talep tahmini ve envanter optimizasyonu (endüstri mühendisliği yorumu)	ML tabanlı talep tahmin modelleri ile envanter politika parametreleri arasındaki etki incelenmiş; talep tahmini çıktıları envanter kararlarında kullanılmış	Hata metrikleri: MAPE, MAE; envanter performansı için stok dışı kalma (stockout), toplam maliyet ölçümleri	ML tahminleri kullanılarak envanter maliyetlerinde düşüş ve stok dışı kalma oranlarında iyileşme sağlanabileceği gösterilmiş; hangi algoritmanın daha iyi olduğu veri setine bağlı.
Makine Öğrenmesi ile Hazır Giyim Perakende Sektöründe Satış Tahmini	Salih Ceylan (2024)	Hazır giyim perakendeciliği; yeni ürün satış tahmini	10 kat çapraz doğrulama, çeşitli makine öğrenmesi modelleri gözlemlenmiş	Pearson korelasyon, Kruskal-Wallis testi,	Yeni ürünler için tahmin modelleri oluşturulmuş; öznelik mühendisliği ve model karşılaştırmaları sonucunda en iyi modeller belirlenmiştir.

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMA

Araştırmamızın bu bölümünde: literatürdeki boşluk analizi ve tezin literatüre katkısı, veri setinin tanımı ve keşifsel veri analizi, veri ön işleme süreçleri, özellik mühendisliği uygulamaları, model kurulumu ve hiperparametre optimizasyonu, ve model performans değerlendirmesi başlıklarına yer verilmiştir.

4.1. Araştırmanın Amacı ve Özgün Değeri

Günümüzde işletmeler, karar alma süreçlerinde daha hızlı ve doğru sonuçlar elde etmek amacıyla veri odaklı yaklaşımlara yönelmektedir. Özellikle satış tahmini, pazarlama stratejileri, stok yönetimi ve finansal planlama gibi kritik iş süreçlerinde işletmelerin rekabet avantajı kazanmasında hayati bir rol oynamaktadır. Geleneksel satış tahmin yöntemleri, geçmiş satış verilerine ve yönetsel deneyimlere dayanmakta, ancak veri hacminin artması ve karmaşıklığın yükselmesiyle birlikte bu yöntemler sınırlı doğruluk ve genelleme kabiliyeti sunmaktadır (Türkmenoğlu ve Tantı, 2014). Bu durum, özellikle büyük veri ortamlarında ve çok değişkenli pazarlarda tahminlerin güvenilirliğini azaltmakta, işletmelerin stratejik kararlarını olumsuz etkileyebilmektedir.

Literatürde makine öğrenmesi tabanlı satış tahmini üzerine yapılan çalışmalar, genellikle belirli sektörler veya sınırlı veri kümeleri üzerinde yoğunlaşmaktadır. Bunun yanı sıra, mevcut araştırmalar çoğunlukla tek bir algoritmanın performansını ölçmekle sınırlı kalmakta ve model seçiminde veri ön işleme, öznetelik mühendisliği ve hiperparametre optimizasyonu gibi kritik süreçlerin etkisini yeterince ele almamaktadır (Géron, 2022). Ayrıca, satış tahminlerinde farklı dışsal faktörlerin—ekonomik göstergeler, tüketici davranışları ve piyasa dinamikleri gibi—model doğruluğuna katkısı literatürde sistematik olarak incelenmemiştir. Bu durum, işletmelerin mevcut tahmin modellerini uygularken belirsizlikle karşılaşmasına ve karar süreçlerinde eksik bilgiye dayalı riskler almasına yol açmaktadır.

Bahsi geçen eksikliklere katkı sunmayı amaçlayan bu çalışma, makine öğrenmesi yöntemlerini satış tahmin süreçlerine entegre ederek, hem içsel verileri (geçmiş satışlar, ürün özellikleri) hem de dışsal verileri (piyasa, ekonomik koşullar) kullanarak daha doğru ve güvenilir tahminler elde etmeyi hedeflemektedir.

Ayrıca, farklı algoritmaların karşılaştırmalı analizini yaparak, hangi modelin hangi koşullarda daha yüksek performans gösterdiğinin ortaya konulması, bu tezin literatüre metodolojik bir katkı sunma bakımından mevcut çalışmalardan farklılaşmaktadır. Sonuç olarak, tez kapsamında geliştirilecek model ve öneriler, işletmelerin satış stratejilerini optimize etmesine, stok ve üretim planlamasını iyileştirmesine ve karar alma süreçlerinde veri temelli yaklaşımı güçlendirmesine olanak sağlayacaktır.

4.2. Yöntem

Bu çalışmada, süpermarket satış verileri kullanılarak makine öğrenmesi yaklaşımı satış tahminleme problemi ele alınmıştır. Süreç; veri setinin hazırlanması, keşifsel veri analizi, veri ön işleme, özellik mühendisliği, model kurulumu ve performans değerlendirme aşamalarından oluşmaktadır. Yöntemin bu şekilde ilerlemesi, veri yapısının detaylı şekilde analiz edildiği ve tahminleme sürecinde model performansını artırmaya yönelik sistematik bir yaklaşımın benimsendiğini gösterir.

İlk olarak veri setinin genel yapısı incelenmiş, değişkenlerin türleri, dağılımları ve veri kalitesi ele alınmıştır. Özellikle satış cirosunun zaman içerisindeki değişimi ve veri setinde yer alan eksik ya da aykırı gözlemler analiz edilmiştir. Keşifsel veri analizi, modelleme sürecinde kullanılacak değişkenlerin belirlenmesi ve veri yapısının anlaşılması açısından önemli bir adım olmuştur.

Veri ön işleme aşamasında, eksik veriler uygun yöntemlerle giderilmiş ve aykırı değerler belirlenerek veri setinin genel yapısını bozmayacak şekilde düzenlenmiştir. Özellikle satış verilerinde gözlenen uç değerlerin model performansını olumsuz etkilememesi amacıyla aykırı değer analizi gerçekleştirilmiştir. Bunun yanı sıra, tatil günleri ve hafta sonları gibi takvimsel etkiler veri setine dahil edilerek modelin gerçek hayata uyumu güçlendirilmiştir.

Çalışmanın önemli aşamalarından biri olan özellik mühendisliği sürecinde, zaman serisi verisinin yapısına uygun yeni değişkenler oluşturulmuştur. Bu kapsamda

gecikmeli satış değerleri (lag), hareketli ortalamalar (rolling mean), değişim oranları ve mevsimsel dönüşümler gibi özellikler modele dahil edilmiştir. Bu sayede model yalnızca mevcut veriyi değil, geçmiş dönem davranışlarını da dikkate alarak öğrenme gerçekleştirmiştir.

Modelleme aşamasında XGBoost, Random Forest ve LightGBM algoritmaları kullanılmıştır. Bu algoritmalar, çok değişkenli veri yapısını işleyebilme ve doğrusal olmayan ilişkileri yakalayabilme özellikleri nedeniyle tercih edilmiştir (Chen & Guestrin, 2016; Ke vd., 2017). Model performansını artırmak amacıyla hiperparametre optimizasyonu uygulanmış ve en uygun model yapısı belirlenmiştir.

Model performansının değerlendirilmesinde ise zaman serisi yapısına uygun bir doğrulama yaklaşımı benimsenmiştir. Bu kapsamda rolling window yöntemi kullanılarak modelin farklı zamanlardaki tahmin başarısı ölçülmüştür (Hyndman & Athanasopoulos, 2021). Performans değerlendirmesinde MAE, RMSE, MAPE ve R^2 gibi metrikler kullanılarak modeller karşılaştırılmıştır. Bu yöntemle, modelin yalnızca eğitim verisi üzerinde değil, farklı dönemlerde de tutarlı sonuçlar üretip üretmediği değerlendirilmiştir (Makridakis vd., 2020).

Sonuç olarak, bu çalışmada izlenen yöntem, verileri kullanıma hazırlama sürecinden model değerlendirmesine kadar sistemli bir yapı sunmakta olup elde edilen sonuçların güvenilirliğini ve modelin uygulanabilirliğini desteklemektedir.

4.2.1. Veri Setinin Tanımı ve Keşifsel Veri Analizi

Çalışma kapsamında İstanbul'un farklı konumlarında yer alan süpermarketlerin geçmiş 3 yıldaki satış verileri kullanılmıştır. Satış hacminin belirlenmesi için gerekli olan değişkenler sektör uzmanları ve akademisyenlerle belirlenmiş olup, işletmenin operasyonel faaliyetlerinde büyük öneme sahip olan promosyon dönemleri, tatil verileri, stok seviyeleri gibi verilerden yararlanılmıştır. Toplam 1.180.402 satır ve 13 sütundan oluşan, 2021-2023 yıllarını kapsayan bu veri seti, 24 süpermarket, 15 ürün kategorisi ve 87 ana ürün grubunu kapsamaktadır. Hedef değişken olarak da günlük satış cirosu belirlenmiştir.

Bu çalışmada farklı algoritmaların aynı veri seti üzerindeki performansları karşılaştırılarak satış tahminleme problemi için en uygun model belirlenmeye

çalışılmıştır. Bu süreç için belirlenen makine öğrenme modelleri (Random Forest (RF), XGBoost ve LightGBM) karar ağacı tabanlı topluluk öğrenme (ensemble learning) yöntemlerinin özelliğine sahip olduklarından ve çok değişkenli veri yapıları üzerinde güçlü tahmin performanslarına ulaşmaları sebebiyle seçilmiştir. Bu algoritmalarda doğrusal olmayan örüntüleri yakalama ve değişkenler arası etkileşimi çözme konusunda başarılı sonuçlara ulaşılmıştır. Ancak bu model tek aşamada belirlenmemiştir.

İlk aşamada Random Forest (RF) yöntemi veri seti üzerinde sağlam ve yorumlanabilir bir temel model oluşturmak amacıyla tercih edilmiştir. XGBoost ve LightGBM ise gradient boosting yaklaşımını kullanarak hatayı her aşamada azaltarak öğrenen ve özellikle büyük veri setleri üzerinde yüksek tahmin doğruluğu sağlayabilen algoritmalarlardır. Farklı algoritmaların performanslarının karşılaştırılması amacıyla kurulan modeldeki değerlendirmeler büyük ölçüde statik eğitim-test verisi ayırımına dayanarak yapılmıştır. XGBoost ile de veri setinin tahmin edilebilirliği test edilerek başlanan süreçte, zaman serisi yapısında olan satış verileri bağlamında gerçeğe en yakın tahmin için zaman boyutunu daha güçlü bir şekilde ele almayı gerektirmiştir. Gradyan artırma temelli bir algoritma ile devam edilmesi gerektiği, yapılan analizlerde net bir şekilde ortaya konmuştur. LightGBM modelinin bu veri setinde tercih edilmesinin en büyük nedeni, büyük bir veri seti oluşu, hızlı öğrenme kabiliyeti ve karmaşık ilişkileri daha verimli bir şekilde modelleyebilme becerisidir. Diğer yandan, zaman serisi temelli gecikmeli ve hareketli ortalama özellikleri ile bir arada kullanımı sonucunda oldukça stabil sonuçlar sunduğu görülmektedir. Bu farklı algoritmalarla yapılan aşamalı yaklaşım, model seçiminin rastgele olmayıp veri yapısı ve analiz sonuçlarına göre ilerletildiği sistematik bir süreçtir.

Tablo 4.1’de çalışmanın başlangıç aşamasında kullanılan değişkenler ve bu değişkenlere ilişkin kısa açıklamalar sunulmuştur. Değişkenler, modelleme sürecinde satış tahminini etkileyebilecek yapısal, zamansal ve mekânsal bilgileri içermektedir.

Tablo 4.1: Değişkenlerin Adlandırılması

Değişken Adı	Açıklama
Gün	Satış işleminin gerçekleştiği tarih bilgisi
Mağaza No	Satışın yapıldığı süpermarketi temsil eden kodu
Kategori	Ürünün ait olduğu kategori kodu
Kategori Ana Grup	Ürünün bağlı olduğu üst kategori (ana grup) kodu
Satış Ciro	İlgili gün için toplam satış tutarı (TL)
Stok	İlgili gün için mağazada bulunan stok miktarı
Fiziki İşlem	Süpermarkette fiziksel olarak gerçekleştirilen işlem sayısı
Sanal İşlem	Online veya dijital kanallar üzerinden gerçekleştirilen işlem sayısı
Promosyonlu Ürün Sayısı	İlgili gün promosyon kapsamında satılan ürün adedi
Yıl	Satış işleminin gerçekleştiği yıl bilgisi
Teşhir Alanı	Süpermarkette ürünlerin sergilendiği alanın büyüklüğünü veya varlığını temsil eden değişken
X Koordinat	Süpermarketin coğrafi konumunu temsil eden X (enlem/boylam) koordinatı
Y Koordinat	Süpermarketin coğrafi konumunu temsil eden Y (enlem/boylam) koordinatı

Ancak zaman serisi temelli bir tahmin problemi söz konusu olduğundan, tarih değişkeninden ay, haftanın günü ve yılın haftası gibi zamansal özellikler türetilmiş ve veri setine eklenmiştir. Sonuç olarak, Tablo 4.2’de veri setinin 7 kategorik ve 20 sayısal olmak üzere toplam 27 bağımsız değişkenden oluşan zaman serisi analizine uygun bir yapıya dönüştürüldüğü görülmektedir.

Tablo 4.2: Değişkenlerin Türlerine Göre Adlandırılması

Değişken Adı	Değişken Türü	Açıklama
Gün	Zaman	Satış işleminin gerçekleştiği tarih
Mağaza No	Kategorik	Satışın yapıldığı süpermarketi temsil eden kod
Kategori	Kategorik	Ürünün ait olduğu kategori
Kategori Ana Grup	Kategorik	Ürünün bağlı olduğu üst kategori (ana grup)
Satış Cirosu	Sayısal	Günlük toplam satış tutarı (TL)
Stok	Sayısal	İlgili gün mağazada bulunan stok miktarı
Fiziki İşlem	Sayısal	Süpermarkette gerçekleştirilen fiziksel işlem sayısı
Sanal İşlem	Sayısal	Online/dijital kanallar üzerinden yapılan işlem sayısı
Promosyonlu Ürün Sayısı	Sayısal	Promosyon kapsamında satılan ürün adedi
Yıl	Kategorik	Satış işleminin gerçekleştiği yıl
Teşhir Alanı	Sayısal	Süpermarkette ürünlerin sergilendiği alanın büyüklüğünü veya varlığını temsil eden değişken
X Koordinat	Sayısal	Süpermarketin coğrafi konumunu temsil eden X koordinatı
Y Koordinat	Sayısal	Süpermarketin coğrafi konumunu temsil eden Y koordinatı
Yıl_Gün	Sayısal	Tarihin yıl-gün bazlı sayısal karşılığı
Ay	Sayısal	Satışın gerçekleştiği ay
Gün_Ay	Sayısal	Ay içindeki gün bilgisi
Haftanın Günü	Sayısal	Haftanın gününü temsil eden sayısal değişken
Yılın Günü	Sayısal	Yıl içerisindeki gün sırası
Yılın Haftası	Sayısal	Yıl içindeki hafta numarası
Mevsim	Kategorik	Satışın gerçekleştiği mevsim
Tatil Mi	Kategorik	Günün resmî tatil olup olmadığını gösteren ikili değişken
Ay_sin	Sayısal	Ay bilgisinin sinüs dönüşümü
Ay_cos	Sayısal	Ay bilgisinin kosinüs dönüşümü
Gün_Ay_sin	Sayısal	Ay içindeki gün bilgisinin sinüs dönüşümü
Gün_Ay_cos	Sayısal	Ay içindeki gün bilgisinin kosinüs dönüşümü
Haftanın Günü_sin	Sayısal	Haftanın günü bilgisinin sinüs dönüşümü
Haftanın Günü_cos	Sayısal	Haftanın günü bilgisinin kosinüs dönüşümü

4.2.2. Veri Ön İşleme Süreçleri


Bu bölümde, modelleme aşamasına geçmeden önce veri setinin analizi için gerçekleştirilen ön işleme adımlarına yer verilmektedir. Öncelikle ham veri setini modele entegre etmeden önce çeşitli düzenlemeler yapılmıştır. Bu kapsamda, değişkenlerin veri tipleri gözden geçirilmiş, eksik ve aykırı değerler analiz edilerek uygun yöntemlerle ele alınmış ve model performansını artırmaya yönelik gerekli dönüşümler uygulanmıştır.

4.2.2.1. Eksik Verilerin Yönetimi

Veri setindeki eksik değerler incelendiğinde yalnızca stok değişkeninde yaklaşık %2,5 oranında eksik gözlem bulunduğu tespit edilmiştir. Eksik değerlerin veri setinin geneline yayılmadığı gözlenmiştir. Bu nedenle eksik stok değerleri medyan yöntemi ile doldurulmuş ve analiz sonrası veri setinde eksik gözlem kalmamıştır.

Tablo 4.3: Veri Setindeki Eksik Değerler

Eksik Sayı		Eksik %
Stok	29981	2.54



Şekil 4.1: Stok Değişkenine Ait Eksik Veri Oranı

4.2.2.2 Aykırı Değer Analizi

Satış cirosu değişkeninde aykırı değerlerin belirlenmesi amacıyla Interquartile Range (IQR) yöntemi kullanılmıştır. Yapılan hesaplamalar sonucunda birinci çeyrek (Q1) değeri 11,06 TL (örtük tutar), üçüncü çeyrek (Q3) değeri ise 178,40 TL (örtük tutar) olarak bulunmuştur. Bu iki değer arasındaki fark olan IQR değeri 167,34 TL'dir. IQR yöntemine göre hesaplanan alt sınır -239,95 TL, üst sınır ise 429,41 (örtük tutar) TL olarak belirlenmiştir. Satış cirosu değişkeninde toplam 140.176 gözlemin aykırı değer olduğu tespit edilmiştir. Gözlemlenen ilk aykırı değerler, 500 TL (örtük tutar) ve üzerindeki yüksek satış tutarlarından oluşmaktadır. Bu durum, belirli süpermarketlerde ve kategorilerde dönemsel olarak oldukça yüksek satış gerçekleştiğini göstermektedir.


Bu bulgular, veri setinde uç değerlerin önemli bir yer tuttuğunu ortaya koymaktadır. Ancak bu değerler veri setinden doğrudan çıkarılmamış, satış davranışının gerçek yapısını bozmayacak şekilde sınırlandırma (winsorization) yaklaşımı tercih edilmiştir.

Tablo 4.4: IQR Yöntemine Göre Bulunan Değerler


İstatistik	Değer
Q1 (1. Çeyrek)	11,06
Q3 (3. Çeyrek)	178,4
IQR (Q3 – Q1)	167,34
Alt Sınır	-239,95
Üst Sınır	429,41
Aykırı Gözlem Sayısı	140.176

Tablo 4.5: Veri Setine Ait Değerler (İlk 5 Satır)

Gün	Mağaza No	Kategori	Kategori Ana Grup	Satış Cirosu	Stok	Fiziki İşlem	Sanal İşlem	Promosyonlu Ürün Sayısı	Yıl	Teshir Alanı	X Koordinat	Y Koordinat
1.01.2021	2	3	200	572,27	508,7	44,5	70,5	11,5	2021	2300	29,06	40,96
1.01.2021	2	3	210	507,15	1146,2	26	57	27	2021	2300	29,06	40,96
1.01.2021	2	4	300	766,34	15275,3	188	117	3,5	2021	2300	29,06	40,96
1.01.2021	2	4	305	567,76	7505,07	272,5	196,5	2	2021	2300	29,06	40,96
1.01.2021	2	5	310	581,6	3885,5	121,5	121	16,5	2021	2300	29,06	40,96




Şekil 4.2: Satış Cirosu Değişkenine Ait Kutu Grafiği (Box Plot)



Şekil 4.3: Satış Ciroosu Değişkenine Ait Frekans Dağılımı

Veri setinin başlangıçtaki boyutu 1.180.402 satırdan ve 13 sütundan oluşmaktaydı. IQR yöntemine göre belirlenen aykırı değerlerin temizlenmesi sonrası veri seti 1.040.226 satır ve 13 sütun olarak güncellenmiştir. Bu işlem sonucunda toplam 140.176 gözlem veri setinden çıkarılarak modelleme sürecinde aşırı uç değerlerin etkisi azaltılmış ve daha dengeli bir veri yapısı elde edilmiştir.




Şekil 4.4: Satış Ciroosunun Zaman Serisi Görünümü

4.2.2.3. Tatil ve Özel Günlerin Modele Entegrasyonu

Satış verilerinde tatil ve hafta sonu etkisinin bulunup bulunmadığını incelemek amacıyla, tatil günleri, hafta sonları ve haftanın günlerine göre ortalama satış ciroları incelenmiştir. Yapılan analizler sonucunda, tatil günlerinde ortalama satış cirosunun normal günlere kıyasla daha düşük olduğu, hafta sonlarında ise hafta içine göre sınırlı bir artış gözlemlendiği tespit edilmiştir.

Analiz edilen veri seti içerisinde toplam 46.085 resmi tatil günü ve 334.016 hafta sonu günü bulunmaktadır. Tatil günlerinde kategori bazlı satış performansı incelendiğinde, bazı ürün gruplarında satışların arttığı, bazı kategorilerde ise azaldığı görülmüştür.



Şekil 4.5: Tatil Günleri ve Haftanın Günlerine Göre Satış Cirosu Analizleri

4.3. Bulgular ve Tartışma

Bu çalışmada özellik mühendisliği süreci iki aşamada ele alınmıştır. İlk aşamada veri setinin tahmin edilebilirliği test edilmiş, belirlenen takvim tabanlı değişkenler entegre edilmiştir. İkinci aşamada ise satış tahmini literatüründe yaygın olarak kullanılan zaman serisi türevli özellikler oluşturulmuştur.

4.3.1. Özellik Mühendisliği Uygulamaları (Feature Engineering)

4.3.1.1. Birinci Aşama: Takvim Tabanlı Özelliklerin Oluşturulması

Araştırmanın bu safhasında, takvimsel değişikliklerin satışları etkileyip etkilemediğini gösterebilmek amacıyla tarih değişkeninden yıl, ay, ay içindeki gün, haftanın günü, yılın günü ve yılın haftası gibi değişkenler oluşturulmuştur. Bununla birlikte, mevsim bilgisi kategorik bir değişken olarak tanımlanmış ve resmi tatil günleri de “Tatil_Mi” değişkeni veri setine eklenmiştir.

4.3.1.2. İkinci Aşama: Zaman Serisi Tabanlı Özelliklerin Oluşturulması

Bu aşamada, satış tahmini literatüründe kullanıldığı görülen gecikmeli (lag) ve hareketli ortalama (rolling) temelli özellikler oluşturulmuştur. Satış cirosunun 7, 14, 21 ve 28 gün önceki değerleri gecikmeli değişkenler olarak hesaplanırken, buna ilaveten 7, 14 ve 30 günlük hareketli ortalamalar oluşturulmuştur. Zaman serilerinde genellikle sık karşılaşılan döngüsel yapının doğru bir şekilde ifade edilebilmesi için, ay ve haftanın günü gibi periyodik olan değişkenler sinüs ve kosinüs dönüşümleri ile kodlanmıştır.


4.3.1.3. Özellikler Mühendisliği Sürecinin Özeti

Özellik mühendisliği sürecinin sonunda, veri seti günlük bazda yeniden yapılandırılarak zaman serisi analizine uygun hale getirilmiştir. Sonuç olarak veri seti, satışların geçmiş davranışını, kısa dönemli eğilimlerini ve mevsimsel yapısını birlikte

gösterecek biçimde yeniden oluşturulmuştur. Böylelikle modelin daha gerçeğe yakın tutarlı sonuçlar ortaya çıkarması sağlanmıştır.

Şekil 4.6'da sunulan korelasyon matrisi incelendiğinde, satış cirosu ile 7 günlük gecikmeli ciro (Ciro_Lag_7) ve 7 günlük hareketli ortalama (Ciro_Rolling_7) değişkenleri arasında oldukça yüksek ve pozitif yönlü bir ilişki bulunduğu görülmektedir. Bu durum, satışların geçmiş dönem performansından güçlü şekilde etkilendiğini göstermektedir. Fiziki işlem, sanal işlem ve promosyonlu ürün sayısı değişkenleri ile satış cirosu arasında orta düzeyde pozitif ilişkiler bulunurken, tatil değişkeni ile düşük ve negatif yönlü bir ilişki gözlemlenmiştir.


Bu bulgular, zaman gecikmeli değişkenlerin modelde yer almasının metodolojik olarak gerekli olduğunu desteklemekte ve satış tahmininde geçmiş dönem bilgisi ile işlem hacmi göstergelerinin önemini ortaya koymaktadır.



Şekil 4.6: Değişkenler Arası Korelasyon Matrisi

Satış cirosu zaman serisi, trend, mevsimsellik ve artık bileşenlerine ayrıştırılarak incelenmiştir. Bulgulara göre, satışlar belirli dönemlerde tekrarlayan mevsimsel bir yapı sergilemektedir. Artık bileşen ise kampanya, stok durumu veya beklenmeyen talep değişimleri gibi modellemesi zor anlık dalgalanmaları göstermektedir.

Bu ayrıştırma sonucunda satış verisi incelenirken dalgalanmalar göz önüne alınarak, zaman boyutunun modelleme sürecinde mutlaka sürece dahil edilmesi gerektiğini ortaya koymaktadır. Bu nedenle çalışmada zaman bazlı eğitim ve test yaklaşımı benimsenmiştir.



Şekil 4.7: Satış Ciro Zaman Serisinin Ayrıştırılması (Trend, Mevsimsellik ve Artık Bileşenler)

Kategori bazlı analiz sonuçlarına göre en yüksek toplam ciroya sahip ilk beş kategori sırasıyla 5., 18., 3., 2. ve 6. kategorilerdir. Özellikle 5 numaralı kategori 34.035.639,64

TL (örtük tutar) toplam ciro ve 279.396 işlem sayısı ile en yüksek hacme sahip olduğu görülmektedir.

Ana grup bazlı analizde ise 100 ve 101 kodlu ana gruplar hem ortalama hem toplam ciro açısından öne çıkmaktadır. Örneğin, 100 kodlu ana grup 8.106.450,60 TL (örtük tutar) toplam ciro üretirken, ortalama ciro değeri 411,59 TL'dir. Bu durum, belirli ana gruplardaki ürünlerin yüksek fiyatlı olduğunu göstermektedir.

Tatil ve normal gün karşılaştırmasında, normal günlerde ortalama satış cirosu 120,59 TL (örtük tutar) iken tatil günlerinde bu değer 105,66 TL'ye düşmektedir. Toplam ciro açısından bakıldığında ise normal günlerde 136.788.400 TL (örtük tutar) seviyesinde satış gerçekleşirken, tatil günlerinde bu değer 4.869.316 TL (örtük tutar) olduğu görülmektedir. Bu sonuçtan yola çıkarak tatil günlerinde genel satış hacminde düşüş yaşandığı söylenebilir.

4.3.2 Model Kurulumu ve Hiperparametre Optimizasyonu

Çalışmanın model geliştirme sürecinde veri yapısı ve elde edilen ara sonuçlar doğrultusunda aşamalı olarak ilerlenmiştir. İlk olarak XGBoost ve Random Forest algoritmaları için hiperparametre optimizasyonu gerçekleştirilerek Grid Search yöntemi ile en uygun parametreler belirlenmiştir. XGBoost modeli için `n_estimators`, `learning_rate` ve `max_depth` parametreleri optimize edilmiş; en iyi sonuçlar `learning_rate=0.1`, `max_depth=9` ve `n_estimators=500` değerleri ile elde edilmiştir. Random Forest modelinde ise `n_estimators` ve `max_depth` parametreleri optimize edilmiştir.

Ancak satış verisinin zaman serisi niteliği taşıması ve gözlemlenen dalgalanmalar nedeniyle model performansı hem XGBoost hem de LightGBM algoritmaları ile yeniden değerlendirilmiştir. XGBoost modelinde daha kapsamlı parametre aralığı kullanılarak derinlik, öğrenme oranı, ağaç sayısı, örnekleme oranı ve düzenleme parametreleri optimize edilmiştir. Benzer şekilde LightGBM modeli için `max_depth`, `learning_rate`, `n_estimators`, `num_leaves`, `subsample` ve düzenleme parametreleri ayarlanmıştır.


4.3.3. Model Performans Değerlendirmesi

Elde edilen bulgular, satış tahmininde zamana bağlı yöntemlerin gerçek performansı ölçmede daha iyi sonuçlar verdiğini göstermektedir. Buradan yola çıkarak, ilk aşamanın modelin "mevcut veriyi açıklama" performansını ölçerken, ikinci aşamanın ise modelin "geleceği öngörme" (forecasting) özelliğini ve gerçek hayata uygunluğunu açıkladığı söylenebilir.


Tablo 4.6: XGBoost ve RF Modellerinin Performans Karşılaştırması

Model	MAE	MSE	R ²
XGBoost (Optimize Edilmiş)	9,89	331,57	0,9654
Random Forest	11,14	429,37	0,9552

Tablo 4.6’da optimize edilmiş XGBoost modelinin Random Forest modeline nazaran hem MAE hem de MSE değerlerinin daha düşük olduğu görülmektedir. Öte yandan R² değerinin 0,9654 olması, satış cirosundaki değişimin büyük bir kısmını açıklayabildiğini göstermektedir. Elde edilen sonuçlar, ilk karşılaştırma aşamasında en başarılı modelin XGBoost olduğunu göstermektedir.



Şekil 4.8: Mağaza, Zaman ve Promosyon Değişkenlerine Göre Satış Ciro
Analizleri



Şekil 4.9: Kategori ve Ana Grup Bazında Satış Ciroosu Analizleri

Tablo 4.7: XGBoost ve LightGBM Modellerinin Performans Karşılaştırması


Model	MAE	RMSE	MAPE (%)	R ²
XGBoost (Default)	20.139,43	21.466,87	9,41	-1,361
LightGBM (Default)	15.298,73	16.968,55	7,23	-0,4752
LightGBM (Optimize Edilmiş)	15.490,05	16.734,64	7,26	-0,4348

Tablo 4.7'ye bakıldığında, zamana bağlı doğrulama sonuçlarının LightGBM modelinde XGBoost'a göre daha düşük hata değerlerinin olduğu görülmektedir. Özellikle MAE ve MAPE değerlerinin LightGBM modelinde oldukça düşük olup R² değerlerinin negatif çıktığı görülmektedir. Bu sonuç modelin tamamen başarısız

olduğunu göstermemekle birlikte, test döneminde gözlenen seviye değişimleri sonucunda R^2 değerinin yanlış yönlendirme yapabileceğini göstermektedir. Bu yüzden sonuçlar analiz edilirken MAE, RMSE ve MAPE değerleri daha fazla göz önünde bulundurulmuştur.


Bu süreçte hareketli doğrulama (Rolling Window Validation) yöntemi kullanılmıştır. Bu yaklaşımda her adımda 12 aylık veri eğitim seti olarak kullanılmış, takip eden 1 aylık dönem test seti olarak değerlendirilmiştir. Bu işlem veri seti boyunca tekrar edilerek modelin farklı dönemlerdeki tahmin başarısı ölçülmüştür. Elde edilen sonuçlara göre ortalama MAE değeri 6.289,11 olarak hesaplanmış, hata değerlerinin standart sapması ise 2.459,01 olarak bulunmuştur. Bu sonuç, modelin dönemsel değişimlere rağmen değişken olmayan istikrarlı bir performans sergilediğini göstermektedir.

Toplam 915 günlük dönem için tahmin üretilmiştir. 2024 yılı için toplam satış cirosu 68.577.661,09 TL (örtük tutar), 2025 yılı için ise 68.367.812,11 TL (örtük tutar) olarak öngörülmüştür. Her iki yıl için tahmin edilen toplam ciro değerlerinin birbirine oldukça yakın olması, modelin mevcut trend ve mevsimsel yapı doğrultusunda dengeli bir tahminleme yaptığını göstermektedir.




Şekil 4.10: Modellerin Hata Metrikleri ve R^2 Skoru Açısından Karşılaştırılması

Ayrıca modelde hangi değişkenlerin daha etkili olduğunu belirlemek amacıyla özellik önem analizi yapılmıştır. Sonuçlara göre en yüksek etki fiziki işlem değişkeni ile gerçekleşmektedir.



Şekil 4.11: Modelde Kullanılan Değişkenlerin Önem Dağılımı

Bu sonuç, mağaza aracılığıyla yapılan satışların ciroyu doğrudan etkilediğini göstermektedir. Bunun ardından 7 günlük değişim (Ciro_Diff_7), 7 günlük gecikmeli satış (Ciro_Lag_7) ve 7 günlük hareketli ortalama (Ciro_Rolling_7) gibi zaman serisi temelli değişkenlerin ön plana çıktığı görülmektedir. Ayrıca sanal işlem, promosyonlu ürün sayısı ve stok değişkenleri de model açısından anlamlı katkı sağlamaktadır.




Şekil 4.12: Rolling Window Validation Sonuçları: Hata Metrikleri ve Gerçek–Tahmin Karşılaştırması

Şekil 4.12’de LightGBM modeline ait grafikler verilmiştir. Gerçek ve tahmin değerleri karşılaştırıldığında, modelin yüksek satış yapılan zamanlardaki tahminlerin gerçeğin altında kaldığını göstermektedir. Residual grafikleri ve hata dağılımı incelendiğinde, hataların sıfır etrafında simetrik dağılmadığını ve pozitif yönde yoğunlaşma gerçekleştirdiğini grafiklerden görmekteyiz.



Şekil 4.13: LightGBM Modeli için Gerçek–Tahmin Karşılaştırması ve Hata Analizleri

Zaman serisi karşılaştırmasında, modelin genel olarak trendi takip ettiğini, fakat ani dalgalanmaları yakalamakta zorlandığı görülmektedir. Bu bulgular sonucunda, satış serisinde seviye değişimi (concept drift) nedeniyle, statik testler yerine zamana bağlı yöntemler ile model performansının değerlendirilmesi daha uygun olmaktadır.



Şekil 4.14: Satış Cirosunun Günlük, Aylık ve Yıllık Trend Analizi

SONUÇ

Bu bölümde İstanbul'daki bazı süpermarket satış verilerinden faydalanılarak, makine öğrenmesi yöntemiyle elde edilen tahmin sonuçları pazarlama teorileri ve literatür alanındaki bilgiler ışığında değerlendirilmiştir. Elde edilen sonuçlar sadece bir istatistiksel performansı göstermekle kalmayıp perakende yönetimi açısından anlamlı bulgular ortaya koymaktadır.

5.1. Bulguların Literatürle Karşılaştırılması

Araştırma bulguları, satış verileri üzerinden gerçekleştirilen tahminleme sonuçlarının zamana dayalı makine öğrenmesi algoritmalarının diğer yöntemlere göre daha yüksek doğrulukta olduğunu göstermektedir. Zaman bazlı doğrulama sonucunda bulunan hata değeri (MAPE) %7,23 olarak bulunmuştur. Bu değer literatürde bahsi geçen M4 ve M5 yarışmalarında (Makridakis ve ark., 2018; 2020) raporlanan hata oranlarının altında kalarak küresel ve büyük ölçekli yarışmalarda gözlemlenen makine öğrenmesi algoritmaları başarısının bir süpermarketin şubelerinde de geçerli olduğunu göstermiştir. Diğer yandan, Nacar (2021) yaptığı çalışmada Random Forest modelinin çok daha başarılı olduğunu raporlamıştır. Ancak bu tez çalışmasında veri hacminin çok büyük oluşu ve zaman serisinin yapısı göz önünde bulundurulduğunda, LightGBM modelinin daha doğru ve dengeli sonuçlar ürettiği gözlemlenmiştir.

Bu sonuç ise Ke ve ark. (2017) tarafından yapılan çalışmada LightGBM'in büyük veri setlerinde sağladığı hız ve verimlilik üstünlüğü ile örtüşmektedir. Ayrıca Sinap (2024) tarafından mağaza bazlı farklılıkların satış performansı üzerindeki etkisinin incelendiği çalışmanın sonuçları bu tez çalışmasında da doğrulanmıştır. Farklı mağazaların ve konumsal olarak eklenen değişkenlerin modele anlamlı bir katkı sağladığı, satış cirosunu etkileyen unsurlar arasında yalnızca ürünün değil, mağazaya bağlı dinamiklerin de etkili olduğu görülmektedir.

5.2. Modelde Öne Çıkan Değişkenlerin Pazarlama Açısından Değerlendirilmesi

Çalışmada kullanılan tahminleme modeli sonucunda, en önemli değişkenin “Fiziki İşlem” olduğu görülmektedir. Bu mağazadaki fiili gerçekleştirmelerin satış

performansını büyük ölçüde etkilediğini ortaya koymuştur. Literatürde de bahsi geçen AIDA modelinde, satın alma sürecinin son aşamasında gerçekleşen Action (harekete geçme) boyutunun fiili davranışı temsil ettiği belirtilmektedir (Kotler & Keller, 2016). Bu bilgiden yola çıkarak, mağazalarda gerçekleşen fiziki işlemler ile satış verileri arasındaki ilişki tüketicinin harekete geçme davranışıyla uyumlu olduğunu göstermektedir. Öte yandan Cir_Lag_7 ve Ciro_Diff_7 gibi kısa dönemli gecikmeli değişkenlerin önem derecesinde üst sıralarda görünmesi, satışların geçmiş dönem alışkanlıklarının etkisiyle şekillendiğini ortaya koymaktadır. Bu noktadan yola çıkarak, tüketici davranışlarının sadece rasyonel kararlarla değil, önceki satın alma deneyimleriyle de şekillendiğini desteklemektedir (Foxall, 2010).

Operasyonel faktörlerden olan promosyonlu ürün sayısı ve stok değişkenlerinin model üzerindeki etkisi incelendiğinde, satışların yalnızca taleplerden etkilenmediğinin mağaza içi uygulamalar ve stok yönetimiyle beraber değerlendirilmesi gerektiğini göstermektedir. Özellikle promosyonların satış miktarlarındaki kısa dönemli sıçrama etkileri oluşturabileceği yine literatürde sıkça bahsedilen unsurlar arasındadır (Kotler & Keller, 2016; Blattberg & Neslin, 1990).

Ayrıca araştırmanın başında makine öğrenmesi yöntemleri ile süpermarketlerin satış tahminlemesi uygulamaları sonucunda elde edilen bulguların, tahminleme süreçlerinin iyileştirilmesinde, veri temelli finansal stratejiler ve stok yönetiminin belirlenmesinde değerli bir rehberlik sağlayacağı öngörülmekteydi (Nacar, 2021). Araştırmada geliştirilen model neticesinde 2024-2025 yılları için üretilen ciro tahminleri, veri temelli geleceğe dönük planlamalar yapmaları açısından yöneticilere yardımcı olacağı öngörüsünü desteklemektedir.

5.3. Modelin Güçlü Yönleri ve Sınırlılıkları

Çalışmada kullanılan zaman serisine dayalı özellik mühendisliği ile satışlardaki dönemsel yapı modeli yansıtılarak, modelin güçlü yönlerinden biri ortaya konulmuştur. Aynı zamanda gecikmeli satış değişkenleri ve sinüs-kosinüs dönüşümleri modelin mevsimsel ve takvimsel örüntüleri açıklamasını kolaylaştırmıştır. Özellikle LightGBM algoritmasının sağladığı hız ve büyük veri setlerine uyum modelin kullanılabilirliğini artırmıştır.

Ancak tüm bu olumlu katkıların yanında modelin birtakım sınırlılıkları da bulunmaktadır. Özellikle ani talep artışlarının yaşandığı kampanya dönemlerinde veya beklenmeyen satış dalgalanmalarında, analizde yapılan tahminlerin gerçek değerlerin altında kalabildiği görülmektedir. Bu sonuç Concept Drift problemi olarak literatürde anılan veri zaman içindeki değişimi problemi ile açıklanabilir (Gama et al., 2014). Artık (residual) analizlerinde de görüldüğü üzere, çalışmada kullanılan model aşırı tahmin üretmek yerine daha temkinli ve tutarlı bir tahminleme eğilimi izlemektedir.

5.4. Araştırmacılar ve Uygulamacılara Öneriler

Araştırmanın modelinde yapılan tahminlerin oldukça başarılı sonuçlar ürettiği görülmektedir. Bununla birlikte, farklı yöntemlerde elbette geliştirilebilir. Özellikle ani talep değişikliklerini daha iyi yakalaması amacıyla Long Short-Term Memory (LSTM) veya Gated Recurrent Unit (GRU) gibi hibrit derin öğrenme modelleri kullanılabilir.

Literatürde bu tür zaman serisi problemlerinde etkili sonuçlar üretebildiği görülmektedir (Hochreiter & Schmidhuber, 1997; Cho et al., 2014). Bunun yanında, rakip fiyatları veya makroekonomik göstergeler eklenerek modelin tahmin performansı artırılabilir. Ayrıca farklı zaman aralıklarında veriye yenileri eklenerek tekrar eğitilmesi satış davranışlarındaki değişimlerin model tarafından güncellenmesini sağlayabilir. Bu da modelin tahminleme performansının daha doğru sonuçlar vermesini beraberinde getirecektir.

5.5. Nihai Değerlendirme

Sonuç olarak, bu çalışma makine öğrenmesi algoritmalarının perakende satış tahmininde özellikle de büyük veri setleri ile çalışırken birden fazla değişkeni aynı anda başarıyla değerlendirebildiğini ve satış davranışındaki karmaşık örüntüleri ortaya çıkarabildiğini göstermiştir. Araştırmada kullanılan veri seti ile gerçekleştirilen analizler, satıştaki değişimlerin yalnızca geçmiş satış değerlerinden değil, işlem sayısı, stok durumu, promosyon uygulamaları ve zamansal faktörler gibi çeşitli değişkenlerin de etkilendiğini ortaya koymuştur.

Elde edilen bulgular, satış tahmininin yalnızca istatistiksel bir hesaplama işlemi değil, aynı zamanda işletmelerin planlama ve karar alma süreçleri açısından stratejik bir unsur olarak değerlendirilmesi gerektiğini göstermiştir. Bu sebeple de ortaya konulan model, perakende işletmelerinin satış planlaması, stok yönetimi ve kampanya dönemlerini belirleme gibi süreçlerde veri temelli kararlar almasına katkı sağlayabilecek bir yaklaşım sunmaktadır. Diğer yandan, bu çalışma perakende sektöründe satış tahmininin çok değişkenli ve dinamik bir yapıya sahip olduğunu da göstermektedir. Bu nedenle satış tahmin modellerinin güncel verilerle düzenli olarak güncellenmesi ve farklı veri kaynaklarıyla desteklenmesi, gelecekte daha güçlü tahmin sonuçları elde edilmesine katkı sağlayabilir.



KAYNAKÇA

Acar, S. C., ve Torlak, Ö. (2022). Algılanan sosyal medya pazarlamasının tüketicinin satın alma davranışına etkisi: Bir derleme çalışması. *İstanbul Ticaret Üniversitesi Girişimcilik Dergisi*, 6(11): 46-61.

Acı, M., ve Ayyıldız Doğanşoy, G. (2022). Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini. *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 37(3): 1325-1340.

Agrawal, R., Imielinski, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. *ACM SIGMOD Record*, 22(2): 207-216.

Akkaya, G. (2007). Yapay sinir ağları ve tarım alanındaki uygulamaları. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 38(2): 195-202.

Aksoy, S. Z. (2008). *Kurumsal Kaynak Planlaması Yazılımlarında Talep Tahmin Yöntemleri ve Uygulamaları* (Yüksek Lisans Tezi). İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Alin, A. (2010). Multicollinearity. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(3): 370-374.

Alpar, R. (2022). *Uygulamalı istatistik ve geçerlik-güvenirlik*. Detay Yayıncılık.

Armstrong, J. S. (Ed.). (2001). *Principles of forecasting: A handbook for researchers and practitioners*. Springer.

Arslan, İ. K., ve Yavuz, A. (2020). Sosyal medyanın tüketici satın alma davranışları üzerindeki etkisi. *İstanbul Ticaret Üniversitesi Girişimcilik Dergisi*, 4(8): 151-170.

Aytekin, B., ve Aydınocak, E. (2022). Perakendecilerin Omni-Channel Kabiliyetinin Müşteri Alışveriş Deneyimine Etkisi. *Journal of Research in Business*, 7(2): 624-642.

Ayyıldız, E., Erdoğan, M., ve Taşkın, A. (2021). Forecasting COVID-19 recovered cases with Artificial Neural Networks to enable designing an effective blood supply chain. *Computers in Biology and Medicine*, 139.

Bakan, Z., ve Kanbay, F. (2024). Makine öğrenmesi yöntemleri ile eğitim başarısına etki eden faktörlerin modellenmesi. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*.

Baldauf, A., Cravens, D. W., & Piercy, N. F. (2005). Sales management control research—synthesis and an agenda for future research. *Journal of Personal Selling & Sales Management*, 25(1): 7-26.

Bandara, K., Bergmeir, C., & Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140: 112896.

Barutçu, S., ve Sezgin, S. (2012). Satış yönetimi sürecinde motivasyon araçları ve etki düzeyleri: Tıbbi satış temsilcileri üzerinde bir araştırma. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(2): 89-97.

Bayar Serbest, A. (2024). *Makine Öğrenmesi ile Talep Tahmini ve Envanter Yönetimi* (Yüksek Lisans Tezi). Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü.

Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A Comparative Analysis of Gradient Boosting Algorithms. *Artificial Intelligence Review*, 54: 1937–1967.

Bilgi Teknolojileri ve İletişim Kurumu. (2022). *Makine öğrenmesi terminolojisi ve model eğitim süreçleri*. BTK Akademi Yayınları.

Blattberg, R. C., & Neslin, S. A. (1990). *Sales promotion: Concepts, methods, and strategies*. Prentice Hall.

Bolt, G. (1994). *Market and sales forecasting*. Kogan Page.

Bose, I., & Mahapatra, R. (2020). Business data mining: Machine learning applications in retail analytics. *Expert Systems with Applications*, 145: 113108.

Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2015). *Time series analysis: Forecasting and control*. Wiley.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1): 5-32.

Brynjolfsson, E., Hitt, L. M., & Kim, H. H. (2011). Strength in numbers: How does data-driven decision-making affect firm performance? *MIT Sloan School of Management*.

B y k zt rk, Ő. (2023). *Sosyal bilimler i in veri analizi el kitabı* (29. baskı). Pegem Akademi.

Can, H. N. (2010). *İŐletmeden İŐletmeye Satıő ve Kiőisel Satıő S recinde Performans Y netimi* (Y ksek Lisans Tezi). İstanbul Teknik  niversitesi Fen Bilimleri Enstit s .

Celebi, M. E., Kingravi, H. A., & Vela, P. A. (2013). A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert Systems with Applications*, 40(1): 200-210.

Cengiz, E. ve  zden, B. (2002). Perakendecilikte b y k zincir marketler ve t keticilerin b y k zincir marketler ile ilgili tutumlarını tespit etmeye y nelik bir araőtırma. *Ege Academic Review*, 2(1).

Ceylan, S. (2024). *Makine  ğrenmesi ile Hazır Giyim Perakende Sekt r nde Satıő Tahmini* (Y ksek Lisans Tezi). Yıldız Teknik  niversitesi, Fen Bilimleri Enstit s , İstanbul.

Cleveland, M., Rojas-Méndez, J. I., Laroche, M., & Papadopoulos, N. (2016). Identity, culture, dispositions, and behavior: A cross-national examination of globalization and culture change. *Journal of Business Research*, 69(3): 1090-1102.

Comegys, C., Hannula, M., & Väisänen, J. (2006). Longitudinal comparison of finnish and us online shopping behaviour among university students: The Five-Stage Buying Decision Process. *Journal of Targeting, Measurement and Analysis for Marketing*, 14(4): 336-356.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3): 273–297.

Cunningham, J. P., & Ghahramani, Z. (2015). Linear dimensionality reduction: Survey, insights, and generalizations. *Journal of Machine Learning Research*, 16: 2859-2900.

Çelik, Y., Karagöz, Y., ve Yavuz, S. (2004). Veri madenciliği yöntemlerinin uygulama alanları. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 12: 1–12.

Çiçek, İ., ve Demir, E. (2017). *Satış ve satış yönetimi*. Nobel Akademik Yayıncılık.

Darley, W. K., Blankson, C., & Luethge, D. J. (2010). Toward an integrated framework for online consumer behavior and decision-making process: A review. *Psychology & Marketing*, 27(2): 94-116.

Demir, K. (2023). Gözetimsel öğrenme algoritmaları ve yapay sinir ağlarında uygulama alanları. *Bilgisayar Bilimleri Dergisi*, 12(4): 178-195.

Demirtaş, O., ve Özcan, A. (2020). Perakende sektöründe satış tahmini ve stok yönetimi. *Ege Akademik Bakış*, 20(2): 203–218.

Diler, S., ve Demir, Y. (2024). Çoklu doğrusal bağlantı olması durumunda veri madenciliği algoritmaları performanslarının karşılaştırılması. *Nicel Bilimler Dergisi*, 6(1): 40-67.

Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10): 78-87.

Ege, İ. ve Bayrakdaroğlu, A. (2009). BIST Şirketlerinin Hisse Senedi Getiri Başarılarının Lojistik Regresyon Tekniği ile Analizi. *ZKÜ Sosyal Bilimler Dergisi*, 5(10): 139–158.

Erciş, A., Ünal, S., Polat, C. (2007). Yaşam Tarzlarının Satın Alma Karar Süreci Üzerindeki Rolü. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2).

Erdemir, N. (2017). *Tutundurma Karması Mecrası Olarak Sosyal Medya: Tüketici Satın Alma Davranış Sürecindeki Yeri* (Yüksek Lisans Tezi). İstanbul Ticaret Üniversitesi, Dış Ticaret Enstitüsü, İstanbul.

Eroğlu, A., ve Bayraktar Köse, E. (2020). Perakende satış tahmininde yapay sinir ağları ve ARIMA modellerinin karşılaştırılması. *İşletme Araştırmaları Dergisi*, 12(1): 426-439.

Farrar, D. E., & Glauber, R. R. (1967). Multicollinearity in regression analysis: The problem revisited. *The Review of Economics and Statistics*, 49(1): 92-107.

Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8): 861-874.

Fernández, A., Garcia, S., Herrera, F., & Chawla, N. V. (2018). SMOTE for learning from imbalanced data: Progress and challenges, marking the 15-year anniversary. *Journal of Artificial Intelligence Research*, 61: 863-905.

Frank, E., Trigg, L., Holmes, G., & Witten, I. H. (2000). Naive Bayes for regression. *Machine Learning*, 41(1): 5-25.

Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *Annals of Statistics*, 29(5): 1189–1232.

Fry, T., & Steele, M. (2020). Improving retail demand forecasting using machine learning. *Journal of Retail Analytics*, 6(3): 15–27.

Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4): 1–37.

Genuer, R., Poggi, J. M., & Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31(14): 2225-2236.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Guo, G., Wang, H., Bell, D., Bi, Y., & Greer, K. (2003). KNN model-based approach in classification. *Lecture Notes in Computer Science*, 2888: 986-996.

Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.

Hahsler, M., Grün, B., & Hornik, K. (2005). arules - A computational environment for mining association rules and frequent item sets. *Journal of Statistical Software*, 14(15): 1-25.

Han, J., Pei, J., & Kamber, M. (2011). *Data mining: Concepts and techniques* (3. baskı). Elsevier.

Han, J., Pei, J., & Yin, Y. (2000). Mining frequent patterns without candidate generation. *ACM SIGMOD Record*, 29(2): 1-12.

Hassani, H., Huang, X., & Silva, E. S. (2018). Big Data and Forecasting: Theory and Practice. *Big Data Research*, 12: 3–8.

Haykin, S. (2009). *Neural Networks and Learning Machines* (3. baskı). Upper Saddle River, NJ: Pearson.

Helland, I. S. (2001). Some theoretical aspects of partial least squares regression. *Chemometrics and Intelligent Laboratory Systems*, 58(2): 97-107.

Hochreiter, S., and Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8): 1735–1780.

Hodkinson, C. (2019). 'Fear of Missing Out' (FOMO) marketing appeals: A conceptual model. *Journal of Marketing Communications*, 25(1): 65-88.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3. baskı). Melbourne: OTexts.

Işık, H. (2020). *Moda perakendesi sektöründe klasik ve makine öğrenmesi metodları ile satış tahmini* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.

İslamoğlu, A. H., ve Altunışık, R. (2007). *Satış ve Satış Yönetimi*. Sakarya Yayıncılık.

Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8): 651-666.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245): 255–260.

Kalaycı, Ş. (Ed.). (2005). *SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri*. Ankara: Asil Yayın Dağıtım.

Kara, A., ve Kök, R. (2019). Türkiye'de elektrik tüketiminin zaman serisi analizi ile tahmini. *Enerji, Piyasalar ve Düzenleme Dergisi*, 9(2): 1–16.

Karafakioğlu, M. (2012). *Pazarlama İlkeleri*. İstanbul: Literatür Yayınları.

Karagöz, Y. (2021). *SPSS ve AMOS uygulamalı nitel-nicel veri analizi*. Nobel Yayınları.

Kazan, S., ve Karakoca, H. (2019). Makine öğrenmesi ile ürün kategorisi sınıflandırması. *Sakarya University Journal of Computer and Information Sciences*, 2(1): 18-19.

Keskenler, M. F. (2017). Makine Öğrenmesi Algoritmaları ve Uygulama Alanları. *Bilişim Teknolojileri Dergisi*, 10(3): 245–256.

King, R. A., Racherla, P., & Bush, V. D. (2014). What we know and don't know about online word-of-mouth: A review and synthesis of the literature. *Journal of Interactive Marketing*, 28(3): 167-183.

Koh, Y. W., Joseph, M. H., & Sivakumar, V. (2024). Big Mart sales prediction using machine learning. *Asia Pacific University of Innovation and Technology*, Kuala Lumpur, Malaysia.

Kotler, P., & Keller, K. L. (2016). *Marketing management*, bs.15, Pearson.

Kotler, P., & Armstrong, G. (2020). *Principles of Marketing* , bs.18, Pearson.

Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. *Informatica*, 31(3): 249-268.

Koyuncugil, A. S., ve Özgülbaş, N. (2009). Veri madenciliği: Tıp ve sağlık hizmetlerinde kullanımı ve uygulamaları. *Bilişim Teknolojileri Dergisi*, 2(2): 21–29.

Kozyrev, S. V. (2012). Classification by ensembles of neural networks. *P-Adic Numbers, Ultrametric Analysis, and Applications*, 4(1): 27-33.

Koçel, T. (2020). *İşletme yöneticiliği*. Beta Yayıncılık.

Krishna, A., & Schwarz, N. (2014). Sensory marketing, embodiment, and grounded cognition: A review and introduction. *Journal of Consumer Psychology*, 24(2): 159-168.

Kıyak, A. (2024). *Tüketicilerin yeşil pazarlama ürünlerine karşı tutumlarının müşteri memnuniyeti üzerine etkisi: Kayseri ili uygulaması* (Yüksek lisans tezi). Sivas Cumhuriyet Üniversitesi.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553): 436-444.

Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of the research literature. *European Journal of Operational Research*, 247(1): 124–136.

Levy, M., and Weitz, B. A. (2004). *Retailing Management*, bs.5, New York: McGraw-Hill.

Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3): 18-22.

Lilien, G. L., Rangaswamy, A., and De Bruyn, A. (2017). *Principles of Marketing Engineering and Analytics*, bs.3, DecisionPro.

Litman, T. (2020). *Autonomous vehicle implementation predictions*. Victoria Transport Policy Institute.

Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and applications*. John Wiley & Sons.

Martín, D., García, A., & Sánchez, J. (2022). Machine learning models for retail sales forecasting: A comparative analysis. *Expert Systems with Applications*, 201: 117179.

Metlek, S., ve Kayaalp, M. L. (2020). Makine Öğrenmesi Yöntemleri ile Satış Tahmini. *Bilişim Teknolojileri Dergisi*, 13(2): 145–156.

Meyer, C., & Schwager, A. (2007). Understanding customer experience. *Harvard Business Review*, 85(2): 116–126.

McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5(4): 115–133.

Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.

Mitchell, V. W. (1999). Consumer perceived risk: Conceptualisations and models. *European Journal of Marketing*, 33(1/2): 163-195.

Moncrief, W. C., & Marshall, G. W. (2005). The evolution of the seven steps of selling. *Industrial Marketing Management*, 34(1): 13-22.

Nacar, E. N. (2021). *Veri analitiği ile satış tahmini: Makine öğrenmesi yaklaşımı* (Yüksek Lisans Tezi). Ankara Yıldırım Beyazıt Üniversitesi, Fen Bilimleri Enstitüsü.

Noble, W. S. (2006). *A biologist's introduction to support vector machines*. University of Washington.

Odegua, R. (2020). *Applied machine learning for supermarket sales prediction*. Project: Predictive Machine Learning in Industry.

Orel Demirci, F. (2003). Gıdaya Dayalı Küçük Ölçekli Perakendecilerin Süper ve Hiper Karşısında Tutunma Yolları. *İktisat/İşletme ve Finans Dergisi*, 209: 63-77.

Özdemir, A., ve Özdemir, A. (2006). Talep tahminlemede kullanılan yöntemlerin karşılaştırılması: Seramik ürün grubu firma uygulaması. *Ege Academic Review*, 6(2): 105-114.

Öztemel, E. (2012). *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul.

Öztürk, A. (2017). *Pazarlama ilkeleri* (Gözden geçirilmiş 3. baskı). Gazi Kitabevi.

Öztürk, M. (2021). Makine öğrenmesinde model hataları ve optimizasyon teknikleri. *Veri Bilimi Dergisi*, 8(2): 112-128.

Öztürk, N. (2013). *Ticaret ve Perakende*. Hayat Yayınları.

Panagopoulos, N. G., & Avlonitis, G. J. (2010). Performance implications of sales strategy: The moderating effects of leadership and environment. *International Journal of Research in Marketing*, 27(1): 46-57.

Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2): 1883.

Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1): 81-106.

Quinlan, J. R. (1993). *C4.5: Programs for machine learning*. Morgan Kaufmann.

Rodriguez, A., & Laio, A. (2014). Clustering by fast search and find of density peaks. *Science*, 344(6191): 1492-1496.

Román, S., & Iacobucci, D. (2010). Antecedents and consequences of adaptive selling confidence and behavior: A dyadic analysis of salespeople and their customers. *Journal of the Academy of Marketing Science*, 38(3): 363-382.

Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3): 210–229.

Saatçioğlu, D., ve Özçakar, N. (2016). Yapay sinir ağları yöntemi ile aralıklı talep tahmini. *Beykoz Akademi Dergisi*, 4(1): 1-32.

SAP. (2021). *AI & machine learning in business*. SAP Press.

Sav, R., Shinde, P., & Gaikwad, S. (2021). Big Mart sales prediction using machine learning. *International Journal of Creative Research Thoughts (IJCRT)*, 9(6): 674–678.

Saygın, E. (2021). *Karaciğer hastalığı teşhisinde makine öğrenmesi yöntemlerinin başarılarının ölçülmesi* (Yüksek lisans tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü.

Saygın, Y. (2021). *Veri madenciliği ve makine öğrenmesine giriş*. Papatya Yayıncılık.

Sevgi, P. (2012). *Hazır giyim perakendeciliği yapan bir firmada yapay sinir ağları ile satış tahmini* (Yüksek lisans tezi). Yıldız Teknik Üniversitesi.

Shareef, M. A., Dwivedi, Y. K., Rana, N. P., Mukherji, B., & Islam, R. (2019). Social Media Marketing: Comparative Effect of Advertisement Sources. *Journal of Retailing and Consumer Services*, 46: 58–69.

Shlens, J. (2014). A tutorial on principal component analysis. *arXiv preprint arXiv:1404.1100*, 1-13.

Sinap, V. (2024). Perakende sektöründe makine öğrenmesi algoritmalarının karşılaştırmalı performans analizi: Black Friday satış tahminlemesi. *Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 27(1): 65–90.

Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3): 199–222.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4): 427-437.

Spiro, R. L., & Weitz, B. A. (1990). Adaptive selling: Conceptualization, measurement, and nomological validity. *Journal of Marketing Research*, 27(1): 61-69.

Şahin, A. (2016). Yeşil Pazarlamada Tüketici Algısı. *Anadolu Tarım Bilimleri Dergisi*, 61.

Şahinaslan, E., Günerkan, M., ve Şahinaslan, Ö. (2023). Makine öğrenmesinde kategorik veri kodlama tekniğinin kullanımına alternatif bir çözüm yöntemi. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 6(1): 1-11.

Şahinaslan, M., Günerkan, H., ve Şahinaslan, Z. (2023). *Makine öğrenmesi ile veri bilimi*. Akademisyen Kitabevi.

Şahinaslan, Ö., Dalyan, H., ve Şahinaslan, E. (2022). Naive Bayes sınıflandırıcısı kullanılarak YouTube verileri üzerinden çok dilli duygu analizi. *Bilişim Teknolojileri Dergisi*, 15(2): 221-225.

Şahinaslan, F. V. (2019). *Makine öğrenmesi algoritmaları ile nüfus tahmini: Türkiye örneği* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.

Şenel, S., ve Alatl, B. (2014). Lojistik regresyon analizinin kullanıldığı makaleler üzerine bir inceleme. *Eğitimde ve Psikolojide Ölçme ve Değerlendirme Dergisi*, 36.

Talih, A. D. (2013). *Sosyal Medya Reklamlarında Tüketici Algılarının Tutum, Davranış ve Satın Alma Niyeti Üzerine Etkisi* (Doktora Tezi). Trakya Üniversitesi Sosyal Bilimler Enstitüsü, Edirne.

Tan, P.-N., Steinbach, M., & Kumar, V. (2019). *Introduction to data mining*, bs.2, Pearson.

Tatlıdil, H. (2002). *Zaman serileri analizi*. Siyasal Kitabevi.

Taylor, J. W., & Bunn, D. W. (1999). A quantile regression approach to generating prediction intervals. *Journal of Forecasting*, 18(4): 299–311.

Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1): 37-45.

Türkmen Ergün, M. (2021). *Makine öğrenmesi yardımıyla online eğitim kurum satışlarının tahmin edilmesi ve COVID-19 pandemisinin etkisinin incelenmesi* (Yüksek Lisans Tezi). Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Türkmenoğlu, B., ve Tantuğ, E. (2014). Büyük veri ve geleneksel yöntemlerin sınırlılıkları. *Veri Bilimi ve Analitik Dergisi*, 6(2): 45–58.

Türkmenoğlu, M., ve Tantuğ, A. C. (2014). Büyük veri ve makine öğrenmesi ilişkisi. *Mühendis ve Makina*, 55(652): 35–45.

Uddin, M. F., Khan, A., Hossain, M. S., & Moni, M. A. (2019). Comparing Different Supervised Machine Learning Algorithms for Disease Prediction. *BMC Medical Informatics and Decision Making*, 19(1): 281.

Ulun, A. (2007). Tüketici Davranışına Yönelik Araştırmalarda Alternatif Bir Teknik: Etnografik Araştırma. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 237-252.

Van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of Machine Learning Research*, 9: 2579-2605.

Verhoef, P. C. (2003). Understanding the effect of customer relationship management efforts on customer retention and customer share development. *Journal of Marketing*, 67(4): 30-45.

Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From multi-channel retailing to omni-channel retailing: Introduction to the special issue on multi-channel retailing. *Journal of Retailing*, 91(2): 174-181.

Wang, G., ve Netemeyer, R. G. (2004). Salesperson creative performance: conceptualization, measurement, and nomological validity. *Journal of Business Research*, 57(8): 805-812.

White, K., Habib, R., & Hardisty, D. J. (2019). How to SHIFT consumer behaviors to be more sustainable: A literature review and guiding framework. *Journal of Marketing*, 83(3): 22-49.

Wu, D. D., ve Olson, D. L. (2020). Introduction To The Special Issue: Artificial intelligence in marketing and management. *Journal of Business Research*, 117: 1–2.

Xu, R., ve Wunsch, D. (2005). Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3): 645-678.

Yang, J. (2022). *Analysis of sales influencing factors and prediction of sales in supermarkets based on machine learning technique*. Chiang Mai University.

Yağcı, M. İ., ve İlarslan, N. (2010). Reklamların Ve Cinsiyet Kimliği Rolünün Tüketicilerin Satın Alma Davranışları Üzerindeki Etkisi. *Doğuş Üniversitesi Dergisi*, 11(1): 138-155.

Yaşa Özeltürkay, E., Bozyiğit, S., ve Gülmez, M. (2017). Instagram'dan alışveriş yapan tüketicilerin satın alma davranışları: Keşifsel bir çalışma. *Marmara Üniversitesi Öneri Dergisi*, 12(48): 175-198.

Yücesoy, M. (2011). *Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Yıldırım, E. (2022). Makine öğrenmesinde aşırı uyum problemi ve çözüm stratejileri. *Yapay Zeka ve Veri Bilimi Dergisi*, 5(3): 215-234.

Yılmaz, A. (2020). *Tüketici kavramı ve modern pazarlama yaklaşımları*. İstanbul: Akademi Yayınları.

Zadeh, L. A. (1996). Fuzzy Logic = Computing with Words. *IEEE Transactions on Fuzzy Systems*, 4(2): 103–111.

Zaki, M. J. (2000). Scalable algorithms for association mining. *IEEE Transactions on Knowledge and Data Engineering*, 12(3): 372–390.

Zhang, G., Patuwo, B. E., and Hu, M. Y. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14(1): 35–62.



EKLER

EK - 1: Özgeçmiş

İlknur PAKSOY

A. İLETİŞİM

Adres:

E-posta:

Telefon:

B. EĞİTİM

Doktora: İstanbul Zaim Üniversitesi (İZÜ), İşletme, 2026, İstanbul

Yüksek Lisans: Marmara Üniversitesi (MÜ), İşletme, Sürdürülebilir Büyüme ve Kalite Yönetimi, 2019, İstanbul

Lisans: Mimar Sinan Güzel Sanatlar Üniversitesi (MSGSÜ), Fen Edebiyat Fakültesi, Matematik, 2010, İstanbul

Lise: Şişli Anadolu Lisesi, 2006, İstanbul

C. İŞ DENEYİMİ

2021 – Devam Ediyor

İstanbul Sabahattin Zaim Üniversitesi (İZÜ), Strateji Geliştirme

2011 – 2016

İstanbul Büyükşehir Belediyesi,

- 2011-2014: Mali Hizmetler
- 2014-2016: Strateji Geliştirme